



ANEXO I: DECLARACIÓN DE NO PLAGIO

D./Dña. LIBNY LISSETTE GONZÁLEZ PINEDA con NIF Y5691526-Y, estudiante de Máster en la Facultad de Ciencias Económicas y Empresariales de la Universidad Complutense de Madrid en el curso 2018-2019, como autor/a del trabajo de fin de máster titulado “ANÁLISIS DE LA RENTABILIDAD DEL SISTEMA BANCARIO PANAMEÑO”, y presentado para la obtención del título correspondiente, cuya tutora es: MARÍA JESÚS SEGOVIA VARGAS

DECLARO QUE:

El trabajo de fin de máster que presento está elaborado por mí y es original. No copio, ni utilizo ideas, formulaciones, citas integrales e ilustraciones de cualquier obra, artículo, memoria, o documento (en versión impresa o electrónica), sin mencionar de forma clara y estricta su origen, tanto en el cuerpo del texto como en la bibliografía. Así mismo declaro que los datos son veraces y que no he hecho uso de información no autorizada de cualquier fuente escrita de otra persona o de cualquier otra fuente. De igual manera, soy plenamente consciente de que el hecho de no respetar estos extremos es objeto de sanciones universitarias y/o de otro orden.

En Madrid, a 11 de junio de 2019

Fdo.:



UNIVERSIDAD COMPLUTENSE DE MADRID

FACULTAD DE CIENCIAS ECONÓMICAS Y EMPRESARIALES

MÁSTER EN CIENCIAS ACTUARIALES Y FINANCIERAS

TRABAJO DE FIN DE MÁSTER

ANÁLISIS DE LA RENTABILIDAD DEL SISTEMA BANCARIO
PANAMEÑO

AUTOR: Libny Lisette González Pineda

TUTOR: María Jesús Segovia Vargas

CURSO ACADÉMICO: 2018/2019

CONVOCATORIA: Junio

ÍNDICE DE CONTENIDOS

RESUMEN DEL TRABAJO	5
ABSTRACT	5
1. INTRODUCCIÓN	6
1.1. SISTEMA BANCARIO PANAMEÑO	6
1.2. RENTABILIDAD DEL SISTEMA BANCARIO PANAMEÑO	8
2. OBJETIVO.....	10
3. MARCO TEÓRICO.....	11
3.1. REVISIÓN DE LA LITERATURA EXISTENTE SOBRE ESTUDIOS PREVIOS DE LA RENTABILIDAD BANCARIA	11
3.2. DESCRIPCIÓN DE LAS VARIABLES UTILIZADAS	13
3.2.1. VARIABLE DEPENDIENTE.....	13
3.2.2. VARIABLES INDEPENDIENTES	14
3.3. DESCRIPCIÓN DE LAS METODOLOGÍAS UTILIZADAS.....	18
3.3.1. ÁRBOLES DE DECISIÓN	18
3.3.2. RED NEURONAL ARTIFICIAL.....	19
3.3.3. ANÁLISIS FACTORIAL	21
4. ANÁLISIS Y RESULTADOS.....	23
4.1. DESCRIPCIÓN DE LA MUESTRA	23
4.2. RESULTADOS	24
4.2.1. ESCENARIO 1: TODAS LAS VARIABLES INDEPENDIENTES	25
4.2.1.1. RESULTADOS DEL ÁRBOL DE DECISIÓN CHAID	25
4.2.1.2. RESULTADOS DE LA RED NEURONAL.....	28
4.2.2. ESCENARIO 2: APLICANDO ANÁLISIS FACTORIAL PARA REDUCIR EL NÚMERO DE VARIABLES	32
4.2.2.1. RESULTADO DEL ANÁLISIS FACTORIAL	33
4.2.2.2. RESULTADO DEL ÁRBOL DE DECISIÓN CHAID.....	37
4.2.2.3. RESULTADO DE LA RED NEURONAL	40
4.2.3. RESUMEN DE RESULTADOS.....	42
5. CONCLUSIONES	43

6. REFERENCIAS	46
7. ANEXOS.....	49

ÍNDICE DE TABLAS

Tabla 1. Clasificación de bancos rentables y no rentables	14
Tabla 2. Variables dependientes e independientes consideradas para predecir la rentabilidad de los bancos	15
Tabla 3. Listado de los bancos utilizados en la muestra.....	23
Tabla 4. Modelos árboles de decisión CHAID para los años 2015-2017. Escenario 1..	27
Tabla 5. Capacidad de predicción del árbol de decisión CHAID para los años 2015-2018. Escenario 1	28
Tabla 6. Matriz de confusión árbol de decisión CHAID. Escenario 1 (2015-2018)	28
Tabla 7. Resumen de la muestra de la red neuronal, 2018. Escenario 1	29
Tabla 8. Capacidad de predicción de la red neuronal, 2018. Escenario 1	30
Tabla 9. Matriz de confusión red neuronal, 2018. Escenario 1	30
Tabla 10. Capacidad de predicción de la red neuronal para los años 2015-2017. Escenario 1	31
Tabla 11. Matriz de confusión red neuronal. 2015-2017. Escenario 1	32
Tabla 12. Pruebas estadísticas para antes de empezar el AF	33
Tabla 13. Comunalidades análisis factorial	34
Tabla 14. Varianza total explicada	35
Tabla 15. Resultado de las cargas factoriales rotadas	35
Tabla 16. Capacidad de predicción del árbol CHAID - factor. Escenario 2	38
Tabla 17. Matriz de confusión modelo CHAID - factor. Escenario 2	39
Tabla 18. Métricas de evaluación escenario 1 y 2	39
Tabla 19. Importancia de los factores en la red neurona. Escenario 2	40
Tabla 20. Capacidad de predicción de la red neuronal - factor. Escenario 2	41
Tabla 21. Matriz de confusión red neuronal - factor. Escenario 2	41
Tabla 22. Métrica de evaluación red neuronal escenario 1 y 2	42
Tabla 23. Resumen de precisión de los modelos	42

ÍNDICE DE FIGURAS Y GRÁFICOS

Gráfico 1. Evolución de la rentabilidad sobre activos del SBN. 2006-2018.....	8
Gráfico 2. Evolución de la rentabilidad sobre patrimonio del SBN. 2006-2018	9
Figura 1. Relación entre una red neuronal y una neurona.	20
Figura 2. Árbol de decisión CHAID, 2018. Escenario 1	26
Figura 3. Red neuronal perceptrón multicapa, 2018. Escenario 1	29
Figura 4. Importancia de las variables independientes. Red neuronal, 2018. Escenario 1	31
Figura 5. Resultado árbol de decisión CHAID con los factores, 2018. Escenario 2.....	38
Figura 6. Red neuronal – factor, 2018. Escenario 2	40

ÍNDICE DE ANEXOS

Anexo 1. Árboles de decisión CHAID. 2015-2017. Escenario 1	49
Anexo 2. Importancia de la variables independientes, árbol CHAID. 2015-2018.....	50
Anexo 3. Redes neuronales. 2015-2017 - Escenario 1	51
Anexo 4. Importancia de las variables independientes.....	54
Anexo 5. Código R para determinar si es adecuado aplicar AF.....	54
Anexo 6. Matriz de correlaciones - Análisis factorial	55
Anexo 7. Ratios financieros calculados para cada banco para el año 2018	56
Anexo 8. Promedio de ratios financieros por año	58

RESUMEN DEL TRABAJO

En este trabajo se evalúa los principales determinantes que influyen en la rentabilidad de los bancos de Panamá, mediante técnicas de árboles de decisión y redes neuronales. El objetivo del trabajo es predecir la rentabilidad bancaria y evaluar cuál de las dos técnicas empleadas es más eficaz para predecir la rentabilidad de los bancos panameños. Se utilizaron los datos de cuarenta y seis bancos durante un período de 2015-2018. Las variables independientes utilizadas se dividieron en factores externos al banco (variables macroeconómicas) y factores internos o específicos del banco (ratios financieros). A su vez, los ratios están divididos para medir liquidez, solvencia, calidad del crédito, eficiencia y tamaño. Como variable dependiente se utilizó el rendimiento sobre los activos (ROA). Los resultados obtenidos indican que la liquidez, la calidad del crédito y la variable control tamaño son importantes para determinar la rentabilidad bancaria. Con el estudio se concluye que la red neuronal artificial es mejor para predecir la rentabilidad del sistema bancario panameño.

PALABRAS CLAVE

Rentabilidad Bancaria, Red Neuronal, Árbol de Decisión, Sistema Bancario Panameño

ABSTRACT

This paper evaluates determinants that influence the profitability of Panama's banks, using decision tree and neural networks. The objective of the research is to predict bank profitability and evaluate which of the two techniques used is most effective in predicting the profitability of Panamanian banks. The data from 46 banks was used during a period of 2015-2018. The independent variables used were divided in factors external to the bank (macroeconomic variables) and internal or specific factors of the bank (financial ratios). At the same time, the ratios are divided to measure liquidity, solvency, credit quality, efficiency and size. As dependent variable, the return on assets (ROA) was used. The results obtained indicate that liquidity, credit quality and variable control size are important to determine bank profitability. Based on the results obtained, it can be concluded that the artificial neural network is better to predict the profitability of the Panamanian banking system.

KEY WORDS

Bank performance, Neural Network, Decision Trees, Panamanian Banking System

1. INTRODUCCIÓN

La rentabilidad bancaria siempre ha sido objeto de estudio y más en los últimos años, debido a las crisis financieras y al desarrollo de la tecnología que obliga a los bancos a ser más competitivos y a cambiar su modelo de negocio tradicional. El hecho de que existan sistemas bancarios más rentables que otros nos lleva a tratar de determinar de qué depende la rentabilidad bancaria. Prueba de ello es que existen numerosos estudios a nivel internacional que utilizan diferentes técnicas estadísticas para analizar cuáles son los factores más importantes que determinan la rentabilidad de un banco. En concreto, destacamos el de Albertazzi, (2016), Alexiou, (2009) y Booyens, (2016) por mencionar algunos.

Este estudio parte del hecho de que siendo la rentabilidad bancaria un tema de estudio actual, en Panamá no existen o son muy escasos los análisis empíricos sobre este tema. Antes de iniciar el estudio se realiza una breve introducción del sistema bancario panameño y de la evolución de su rentabilidad.

1.1. SISTEMA BANCARIO PANAMEÑO

El buen funcionamiento del sector bancario y financiero cumple un papel importante dentro de la economía de un país (Alves et al., 2017). En Panamá, según datos de la Contraloría General de la República para el 2018, este sector, denominado de intermediación financiera, contribuyó en 7,4% al PIB, generó alrededor de 45.237 empleos (26.439 generados por el sector bancario), y presentó un crecimiento de 4,2%¹. Es importante señalar que el Centro Bancario Internacional (CBI) es el que más contribuye al desarrollo de la intermediación financiera panameña con una participación alrededor del 90%².

El CBI fue creado por la Ley Bancaria publicada en el Decreto de Gabinete No.238 de 2 de julio de 1970 y desde entonces, el CBI ha ido evolucionando y fortaleciéndose, siendo un pilar importante de la economía panameña y actualmente es considerado uno de los

¹ Datos obtenidos de las estadísticas publicadas por el Instituto Nacional de Estadística y Censo de Panamá (INEC). Página web: <https://www.contraloria.gob.pa/inec/>.

² Datos obtenidos en la página web de la Superintendencia de bancos de Panamá: <https://www.superbancos.gob.pa/>. (Informe de estabilidad bancaria, 2017)

principales centros financieros de Latinoamérica (Unidad de Monitoreo y Análisis de la Competitividad de Panamá, 2014).

Según datos publicados por la Superintendencia de Bancos de Panamá (entidad encargada de regular y supervisar la banca panameña), a diciembre de 2018 el CBI estaba compuesto por un total de ochenta y cuatro bancos, los cuales se dividen en: dos bancos oficiales (denominados banca oficial), treinta bancos de capital extranjero (denominados banca extranjera), dieciséis bancos de capital privado panameño (denominados banca panameña privada), veinticuatro bancos de licencia internacional y doce bancos con licencia de representación.

La banca extranjera y la banca panameña privada conforman los bancos de licencia general y estos a su vez junto con los bancos oficiales componen el Sistema Bancario Nacional (SBN).

A continuación, se detalla brevemente las tres clases de licencias bancarias que se ofrecen en Panamá:

1. Licencia General: permite realizar el negocio de banca de manera local y extranjera.
2. Licencia Internacional: solo permite realizar el negocio de banca en el extranjero, aunque tienen su oficina en Panamá.
3. Licencia de Representación: permite a bancos extranjeros establecer una oficina de representación desde la cual promueven sus servicios y visitan clientes activos y potenciales, en Panamá y la región.

Los bancos oficiales realizan operaciones comerciales y de consumo de igual manera que un banco de licencia general, con la diferencia que su capital es estatal. Sin embargo, el Banco Nacional de Panamá (BNP), que es oficial, realiza algunas funciones de banco central, ya que el Sistema Financiero panameño tiene la particularidad de no tener un banco central. Las funciones propias que realiza el BNP son: agente financiero y depositario oficial del estado y manejo de la Cámara de Compensación del Sistema Bancario Nacional. Pero no puede emitir billetes ya que Panamá tiene como moneda de curso legal el dólar estadounidense.

Cabe señalar que los bancos oficiales, a efectos de estudio se incluyen en los bancos de licencia general, ya que, como hemos explicado realizan las mismas funciones de un

banco de licencia general y, por tanto, no supone problemas incluirlos en la misma categoría.


Para el estudio se utilizan cuarenta y seis bancos de licencia general que se encontraban en normal funcionamiento al 31 de diciembre de 2018 y que no estaban atravesando ningún proceso de liquidación.

1.2. RENTABILIDAD DEL SISTEMA BANCARIO PANAMEÑO

La rentabilidad está relacionada con la capacidad de generar ganancias o un beneficio, a partir de una inversión o un capital empleado en determinada actividad. De esta manera, refiriéndonos a una entidad bancaria, es el rendimiento que obtiene un banco al realizar sus actividades propias, mediante la utilización de determinados recursos.

La rentabilidad del sistema bancario panameño, a pesar de las crisis económicas, financieras y reputacionales a las que se ha tenido que enfrentar en los últimos años, no ha presentado grandes variaciones. Sin embargo, desde el 2013 la banca no ha alcanzado los mismos niveles de rentabilidad observados en años anteriores (ver Gráficos 1 y 2).

GRÁFICO 1. EVOLUCIÓN DE LA RENTABILIDAD SOBRE ACTIVOS DEL SBN. 2006-2018




Fuente: Elaboración propia

Según datos publicados por la Superintendencia de Bancos de Panamá (SBP), el promedio de la rentabilidad sobre activos (ROA) en el período 2006-2017 fue de 1,61% y al cierre del 2018 se situó en 1,53%. Mientras que la rentabilidad sobre el patrimonio (ROE) presentó un promedio de 13,97% para el mismo período y al 2018 se situó en

13,44%³. Por lo que se puede apreciar que la rentabilidad del SBN se ha mantenido medianamente estable, a pesar de las crisis económicas internacionales que se han dado en los últimos años y de los escándalos reputacionales que ha tenido que enfrentar el país como los “Panama Papers”⁴ y con ello la inclusión de Panamá en diferentes listas por la falta de transparencia fiscal.

GRÁFICO 2. EVOLUCIÓN DE LA RENTABILIDAD SOBRE PATRIMONIO DEL SBN. 2006-2018



Fuente: Elaboración propia

Una de las causas que el sistema bancario panameño mantenga su rentabilidad medianamente estable se debe, quizás, a que la mayoría de los bancos que lo integran son de capital latinoamericano y no les afecta directamente las crisis financieras internacionales (Informe de estabilidad financiera SBP, 2017).

Por otra parte, importante señalar que el sistema bancario al tener tantos bancos, obliga a los bancos a ser más competitivos, brindar un mejor servicio y mejorar su calidad para poder mantener la rentabilidad.

Viendo la complejidad del sistema bancario panameño y las características que presenta su rentabilidad, con este trabajo se busca analizar qué factores influyen en la rentabilidad

³ Todos los porcentajes fueron calculados de las estadísticas publicadas por la Superintendencia de Bancos de Panamá. Página web <https://www.superbancos.gob.pa/>.

⁴ Los Panama Papers es una investigación periodística que expuso los negocios *offshore* de políticos, empresarios y famosos. El objetivo de las *offshore* era evadir impuestos. La investigación se basó en la filtración de millones de documentos de la firma de abogados panameña Mossack Fonseca (actualmente disuelta). Fuente periódico argentino infobae: <https://www.infobae.com/politica/2019/04/09/que-son-los-panama-papers/>.

de los bancos que conforman el SBN mediante árboles de decisión y redes neuronales. Para ello, se ha utilizado una muestra de cuarenta y seis bancos, y diecinueve variables explicativas.

Para medir la rentabilidad se utiliza la rentabilidad sobre activos (ROA) y el análisis se ha estructurado en dos escenarios. Para el primer escenario (lo denominaremos, escenario 1) se utilizan todos los ratios calculados al 2018 y todas las variables macroeconómicas, y se analizan mediante la utilización de árboles de decisión y redes neuronales, además, se hace una comparación de los resultados con los años 2015-2017. Para el segundo escenario (lo denominaremos, escenario 2), se efectúa un análisis factorial por el método de componentes principales, con el fin de reducir el número de variables, y se vuelve a emplear las mismas metodologías que en el primer escenario.

2. OBJETIVO

Por lo anteriormente expuesto, el objetivo de este trabajo es analizar qué factores son determinantes en la rentabilidad del sistema bancario panameño para el año 2018 y establecer qué metodología (árboles de decisión o redes neuronales) es más eficiente para predecir la rentabilidad de los bancos. También se busca hacer una comparabilidad de los resultados obtenidos para el año 2018 con los años 2015-2017 en el primer escenario (escenario 1), con el fin de detectar, si durante al menos cuatro años, la rentabilidad puede ser explicada por los mismos factores, a la vez, que nos permite conocer cuáles serían los determinantes que más se repiten, para concluir mejor cuáles son realmente importantes para explicar la rentabilidad.

Para lograr el objetivo planteado se parte de estudios ya realizados (Abu y Thir, 2009) en el ámbito internacional sobre la rentabilidad bancaria. Dichos estudios sirven de base para identificar las variables que han salido significativas en los mismos y, ha permitido calcular esas mismas variables para la muestra objeto de estudio y así poder realizar el análisis para este trabajo.

3. MARCO TEÓRICO

3.1. REVISIÓN DE LA LITERATURA EXISTENTE SOBRE ESTUDIOS PREVIOS DE LA RENTABILIDAD BANCARIA

Existen diversos estudios con diferentes metodologías estadísticas enfocados a determinar la rentabilidad bancaria y a predecir el fracaso bancario. A continuación, se detallan las más relevantes que han servido de ayuda para sustentar este trabajo:

Enfocado a la quiebra bancaria se destaca el trabajo de Fernández, Bejarano y Vicente (2013), donde utilizan el modelo de árbol de decisión CHAID exhaustivo para la predicción temprana de entidades con problemas de liquidez y solvencia. Para su análisis utilizan ratios financieros y variables macroeconómicas. Su estudio tiene la particularidad que no utilizaron una muestra, sino que aplican el análisis a todos los bancos y cajas de ahorro del sistema financiero español para el período 2005-2012. Calculan 16 ratios que incluyen solvencia, liquidez, tamaño y rentabilidad. Los resultados obtenidos indican que la balanza de pago es el primer predictor utilizado por el modelo para detectar las entidades con problemas, la siguiente variable que incorpora es la solvencia y por último la de tamaño.

Otro trabajo centrado en explicar la rentabilidad bancaria es el estudio de Fuertes García (2016), donde utiliza ratios financieros y variables macroeconómicas para predecir la rentabilidad de los bancos españoles por medio del análisis de regresión múltiple, tomando como variables dependientes el ROA y ROE. El período de estudio considerado para el análisis es del 2005-2015 y luego segmenta el análisis en dos períodos uno antes de la crisis financiera del 2008, que va de 2005-2007 y otro después de la crisis financiera del 2008, que va del 2008-2015. Calculan veintiséis ratios financieros, dos variables de tamaño y consideran 3 variables macroeconómicas. Los resultados muestran que las inversiones inmobiliarias actúan como un determinante negativo para la rentabilidad y que los fondos propios son un determinante que aumenta la rentabilidad.

Mallo et al. (2014), en su artículo sobre el análisis de la rentabilidad de entidades financieras de la República de Argentina utilizan un modelo de árbol de agrupamiento con el algoritmo CRT. Seleccionaron como variable dependiente el ROA y como variables independientes ratios financieros, el período de estudio seleccionado por los autores es 2003-2006. Los ratios financieros los clasifican en endeudamiento, liquidez,

eficiencia, rentabilidad y valor de mercado. Los resultados concluyen que las variables más relevantes para determinar la rentabilidad son los gastos administrativos entre los ingresos netos totales y el apalancamiento del patrimonio neto sobre los activos.

Davydenko (2010), en su estudio para determinar de la rentabilidad de los bancos de Ucrania aplica la metodología de datos de panel para el período de 2005-2009. Como variables independientes utiliza ratios financieros, variables macroeconómicas y también considera variables específicas de la banca, como el índice de concentración de los bancos medido por el total de activos. Los ratios financieros incluidos en este estudio están divididos por la calidad del activo, la fortaleza del capital, eficiencia y liquidez. Para medir la rentabilidad utilizan el ROA, por lo que representa la variable dependiente. Se concluye en base a los resultados obtenidos que la media móvil de la rentabilidad es altamente significativa lo que confirma el carácter dinámico de las ganancias bancarias en Ucrania y también se observa que las provisiones para préstamos son significativas en el modelo y tienen un efecto negativo en la rentabilidad.

Bakar y Mohd (2009), en su investigación para predecir el rendimiento de los bancos de Malasia, utilizan el ROA para medir la rentabilidad de los bancos, y como variables independientes escogieron siete variables que incluyen ratios financieros y variables macroeconómicas, el período de estudio es 2001-2006. Los ratios financieros considerados son de liquidez, riesgo de crédito, relación coste-ingreso y de control tamaño. La metodología que aplican para el análisis es regresión lineal múltiple y una red neuronal. Los resultados de la regresión lineal múltiple muestran que el riesgo de crédito y la relación coste / ingreso son importantes para determinar la rentabilidad de los bancos en Malasia. Los resultados de la red neuronal muestran que las siete variables independientes explican el 66,9% de la variación total de los datos. Entre los dos métodos empleados la red neuronal tiene un mayor poder de predicción de la rentabilidad de los bancos de Malasia.

Petria et al.(2015) , utilizan datos de panel para determinar la rentabilidad de 27 bancos que conforman el sistema bancario de la Unión Europea. Como variables dependientes utilizan el ROA y el ROE. Las variables independientes las dividen en factores propios del banco como liquidez, riesgo de crédito, eficiencia, también consideran variables propias del negocio bancario como la concentración / competencia del mercado y por último añaden las variables económicas. El período de estudio que consideran los autores es de 2004-2011. Las conclusiones a las que llegan es que las mismas variables son

significativas tanto en el ROA como en el ROE entre ellas se destacan el riesgo de crédito, la liquidez, la eficiencia y la concentración / competencia del mercado.

Cabe mencionar que en la mayoría de las publicaciones relacionadas a predecir la rentabilidad bancaria utilizan como variables macroeconómicas el producto interno bruto (PIB) y el índice de precios del consumidor (IPC).

Como conclusión y basándonos en los estudios previos que hemos citado, trataremos de predecir la rentabilidad de los bancos panameños, para lo cual utilizaremos como variable dependiente el ROA. En cuanto a las variables independientes y de acuerdo con la revisión de la literatura efectuada, utilizaremos distintos ratios financieros representativos de la situación económica financiera de los bancos, junto con una selección de variables macroeconómicas.

3.2.DESCRIPCIÓN DE LAS VARIABLES UTILIZADAS

3.2.1. VARIABLE DEPENDIENTE

Las medidas de rentabilidad usualmente más utilizadas son: el rendimiento sobre el patrimonio (ROE), relaciona el beneficio neto sobre el patrimonio; y el rendimiento sobre los activos (ROA), relaciona el beneficio neto sobre el total de los activos (López y Sebastián, 2008). El ROA muestra la capacidad de la administración para generar ganancias a partir de los activos, mientras que el ROE indica el rendimiento neto del capital invertido por los accionistas. En comparación con el ROE, el uso del ROA tiene en cuenta los riesgos derivados del apalancamiento y es el índice clave de rentabilidad bancaria (Alexiou y Vogiazas, 2009). Un inconveniente del ROA es que para su cálculo no toma en cuenta los activos fuera de balance, por lo que para solucionar este inconveniente el uso del ROE es más apropiado (Petria, 2015).

En este estudio para el análisis con el método de árboles de decisión y redes neuronales, se utilizó el ROA para clasificar los bancos en “Rentables” y “No Rentables”, en función al signo de este indicador. El criterio de selección se basa en el estudio realizado por González, Correa y Acosta (2002). Sin embargo, es necesario mencionar que, en nuestro trabajo para efectuar esta clasificación, realmente era indiferente usar el ROA o el ROE ya que para el 2018 ambos tienden a ser similares y con cualquiera de los dos, los bancos quedaban clasificados exactamente igual. En la Tabla 1 se muestra el total de bancos

clasificados en función a su rentabilidad en cada año de estudio. Para realizar el análisis del estudio se toman los activos totales medios para calcular el ROA, como se puede apreciar en la Tabla 2. Aunque en algunos estudios usan la medida con el activo total, se recomienda calcular el ROA con los activos medios, ya que los balances recogen el saldo de las cuentas en un momento dado, mientras que el estado de resultados se refiere a los flujos de ingresos y gastos durante un período determinado. Por tanto, al ser el ROA un ratio que para calcularlo requiere información de ambos lados al relacionar sus valores con el promedio, se evita utilizando los activos medios, comparar el resultado de un período con el de un momento determinado (López, 2008).

TABLA 1. CLASIFICACIÓN DE BANCOS RENTABLES Y NO RENTABLES

	2018	2017	2016	2015
Rentable	40	40	37	38
No Rentable	6	4	7	6
Tota	46	44	44	44

Fuente: Elaboración propia

3.2.2. VARIABLES INDEPENDIENTES

Las variables independientes o explicativas que se utilizan en este estudio se seleccionaron en base a la literatura bancaria y financiera, que se señalaban como variables determinantes significativas de la rentabilidad. También se utilizaron las pautas del libro Gestión Bancaria de López y Sebastián (2008). Las variables fueron adaptadas, según las definiciones contables o financieras que se utilizan en el sistema bancario panameño.

Las variables inicialmente seleccionadas fueron, por un lado, once ratios financieros calculados a partir de la información obtenida de las estadísticas publicadas por la Superintendencia de Bancos de Panamá. Estos ratios miden la liquidez, la calidad del crédito, la solvencia, la eficiencia y la rentabilidad de las respectivas entidades. Por otro lado, hay tres variables de control (las tres miden el tamaño de la entidad considerando diferentes aspectos y los datos para su cálculo fueron obtenidos de las estadísticas publicadas por la SBP correspondiente a cada banco). Finalmente, se han incluido cinco

variables macroeconómicas, obteniendo los datos del Instituto Nacional de Estadística y Censo. En total se analizan 19 variables que están detalladas en la Tabla 2.

TABLA 2. VARIABLES DEPENDIENTES E INDEPENDIENTES CONSIDERADAS PARA PREDECIR LA RENTABILIDAD DE LOS BANCOS

Variables	Definición	Notación
<u>Variable dependiente</u>		
Rentabilidad sobre activos	Utilidad neta / Activo total medio	ROA
<u>Variables independientes</u>		
<u>Variables macroeconómicas</u>		
1. Balanza de pago	Saldo corriente de la balanza de pagos	Balanza
2. Inflación	Índice de precio al consumidor	IPC
3. Actividad económica	Variación del producto interno bruto	PIB
4. Desempleo	Tasa de desempleo	Desempleo
5. Renta nacional	Logaritmo de la renta per cápita	LogPerCapita
<u>Variables de control de tamaño</u>		
6. Tamaño por activos	Logaritmo del total de activos	LogActivo
7. Tamaño por patrimonio	Logaritmo del patrimonio total	LogPatrimo
8. Volumen de negocio	Logaritmo de ingreso por intereses	LogIngreso
<u>Ratios financieros</u>		
Liquidez		
9. Liquidez 1	Activos líquidos / Activo total	LIQ1
10. Liquidez 2	Préstamos totales / Activo total	LIQ2
11. Liquidez 3	Préstamos totales / Depósitos totales	LIQ3
Calidad del crédito		
12. Calidad del crédito 1	Provisiones para préstamos / Préstamos vencidos	CCRED1
13. Calidad del crédito 2	Provisiones para préstamos / Préstamos totales	CCRED2
14. Calidad del crédito 3	Provisiones para préstamos / Activo total	CCRED3
Solvencia		
15. Solvencia 1	Patrimonio total / Activo total	SOLV1
16. Solvencia 2	Patrimonio total / Pasivo total	SOLV2
Rentabilidad		
17. Rentabilidad 1	Ingreso neto de intereses / Activo total medio	RENT1

Variables	Definición	Notación
18. Rentabilidad 2	Resultados de explotación / Activo total medio	RENT2
Eficiencia operativa		
19. Eficiencia	Egreso de operaciones / Ingreso de operaciones	Eficiencia

Fuente: Elaboración propia

A continuación, se explica a detalle, en base a las definiciones de López (2008), Blanco (2015) y Bernal (2010), que mide cada ratio considerado para el análisis:

1. **Logaritmo del total de activos y patrimonio:** se utilizan para medir el tamaño del banco y controlar el efecto que pueda tener sobre la rentabilidad. El activo es la medida más clara del tamaño del banco, el patrimonio mide la parte que poseen los accionistas.
2. **Logaritmo de ingreso por intereses:** mide el volumen de negocio que tiene el banco.
3. **Activos líquidos / Activo total:** los activos líquidos son caja y depósitos en bancos. Los activos líquidos los podemos convertir en dinero de forma rápida y sin perder su valor. Este indicador trata de medir la liquidez.
4. **Préstamos totales / Activo total:** este indicador mide el porcentaje que representan los préstamos sobre el total de los activos. Cuanto menor sea este ratio, mayor será la liquidez, ya que los préstamos tienen muy poca liquidez.
5. **Préstamos totales / Depósitos totales:** compara los préstamos con el total de depósitos. Refleja el porcentaje de activo que es financiada por los depósitos. Y al igual que el ratio anterior, cuanto menor su medida mayor será la liquidez.
6. **Provisiones para préstamos / Préstamos vencidos⁵:** también llamado ratio de cobertura, relaciona las provisiones para préstamos con el total de préstamos dudosos de recuperar o de difícil cobro.
7. **Provisiones para préstamos / Préstamos totales:** indica la proporción de los préstamos que han sido provisionado sin que todavía sean considerados incobrables.

⁵ Se clasificará como préstamo vencido cualquier facilidad crediticia cuya falta de pago de los importes contractualmente pactados presenten una antigüedad superior a 90 días. Normativa bancaria de la Superintendencia de Bancos de Panamá (1998-2017).

- 8. Provisiones para préstamos / Activo total:** conocido como ratio de insolvencia, es la relación entre las provisiones y el activo. Cuanto mayor sea el ratio de insolvencia, el banco puede hacerle frente a más préstamos incobrables sin afectar su resultado.
- 9. Patrimonio total / Activo total:** representa un ratio de solvencia o de endeudamiento, relaciona el patrimonio neto (recursos propios) con el total de activos. Mide la capacidad del banco para soportar las pérdidas. Por tanto, una disminución del ratio indica un aumento a la exposición al riesgo por parte del banco.
- 10. Patrimonio total / Pasivo total:** es usado para medir solvencia y el apalancamiento, es decir, la intensidad de la deuda comparada con el patrimonio o fondos propios. Cuanto mayor sea su valor más independiente es el banco o menor será su apalancamiento y tendrá mejor solvencia.
- 11. Ingreso neto de intereses / Activo total medio:** el ingreso neto de interés o margen de interés, es la diferencia entre los gastos por captar fondos y los ingresos obtenidos por la concesión de préstamos. Con este indicador se busca medir la actividad propia del banco.
- 12. Resultados de explotación / Activo total medio:** el resultado de explotación es originado por el desarrollo de las actividades ordinarias del banco. Se obtiene agregando al ingreso neto de intereses los gastos de personal, de administración, otros gastos generales, amortizaciones y provisiones por deterioro de activos financieros. Este ratio mide la rentabilidad por la actividad recurrente del banco.
- 13. Egreso de operaciones / Ingreso de operaciones:** es una medida de eficiencia de la actividad bancaria. Es la relación entre los ingresos que obtiene el banco y los gastos que incurre para obtener dichos ingresos. Un banco será eficiente si consigue producir con un menor gasto o si puede vender sus productos con un mayor margen. Así, cuanto más bajo es el ratio, más eficiente es la entidad. Se cree que si se mejora la eficiencia se puede aumentar el resultado de la entidad (López, 2008).

3.3.DESCRIPCIÓN DE LAS METODOLOGÍAS UTILIZADAS

Las técnicas utilizadas para el análisis de los datos son los árboles de decisión con el método CHAID, red neuronal con el modelo perceptrón multicapa y el análisis factorial con el método de componentes principales. Estas técnicas se escogieron porque no requieren ninguna hipótesis previa sobre la estructura de los datos (González, 2002).

3.3.1. ÁRBOLES DE DECISIÓN

Los árboles de decisión son un método de aprendizaje supervisado (es decir, se explica cuál es la entrada y cuál es la salida correspondiente a los datos de entrenamiento) y no paramétrico, utilizado para la clasificación y la regresión (Magerman, 1995). El objetivo es crear un modelo que prediga el valor de una variable objetivo mediante el aprendizaje de reglas de decisión simples deducidas por las características de los datos, donde los datos se dividen continuamente de acuerdo a un determinado parámetro. El árbol puede explicarse por dos entes: los nodos de decisión y las ramas. Las ramas son las decisiones o los resultados finales, y los nodos de decisión son los puntos donde se dividen los datos.

Los árboles de decisión asignan una distribución de probabilidad a las posibles opciones de decisión y generan un sistema de clasificación que especifica el orden de preferencia para las posibles decisiones. Es decir, proporciona una medida de probabilidad de cada resultado para analizar cada opción de forma numérica. Esta probabilidad se determina al hacer una secuencia de preguntas, donde la pregunta i -ésima formulada está determinada únicamente por las respuestas a las preguntas anteriores, esto es, por las $i-1$.

Los modelos de árboles de decisión más utilizados son (Pérez, 2014): los árboles CART, los árboles CHAID y los árboles QUEST. Pero, básicamente todos realizan el mismo procedimiento: examinan todos los campos de un conjunto de datos para encontrar el que ofrece la mejor clasificación o predicción al dividir los datos en subgrupos. El proceso se aplica de forma recursiva, dividiendo los subgrupos en unidades cada vez más pequeñas hasta que el árbol esté terminado, según los criterios de parada. Los campos de destino y de entrada utilizados en la construcción del árbol pueden ser continuos o categóricos. Si se usa un objetivo continuo, se genera un árbol de regresión, mientras que, si se usa un objetivo categórico, se genera un árbol de clasificación.

Para este trabajo se utiliza el algoritmo de inducción de reglas denominado CHAID (Chi-squared Automatic Interaction Detection), porque es útil para identificar variables importantes, por su amplia difusión y por las ventajas que presenta. Entre las ventajas se pueden mencionar (Berlanga et al., 2013): a) son tolerantes al ruido, a variables no significativas y valores perdidos; b) es capaz de ejecutar particiones no lineales óptimas para cada variable explicativa mediante la elaboración de tablas de contingencia basadas en el test de bondad de ajuste de la chi-cuadrado, por lo que con una muestra de tamaño aceptable casi siempre produce buenos resultados; c) es de fácil interpretación, aún si no se es un usuario experto; d) la variable dependiente puede tener más de dos categorías, por lo que se pueden tener árboles no binarios, es decir, presentarse más de dos divisiones por nodo; y finalmente e) las clasificaciones o reglas generadas son diferentes, ya que siempre tienen un significado estadístico.

El algoritmo consiste en una serie de análisis de la chi-cuadrado entre la variable dependiente y las variables explicativas. Se divide cada nodo localizando el par de categorías permitidas por el predictor con el menor valor de chi-cuadrado. Si el nivel de significancia es menor que cierto valor crítico, se unen ambas categorías y se repite el proceso. Por el contrario, si es mayor, se convierten en dos candidatas a la división de la variable. Este proceso continúa con cada par de categorías, hasta que dejan de producirse uniones y posibles divisiones. La última candidata a la división (que generalmente no suele coincidir con la división más significativa) es la que se elige para dividir al predictor. El proceso se repite de forma recursiva en cada uno de los nodos, hasta que se activa cualquiera de las reglas de parada del proceso.

3.3.2. RED NEURONAL ARTIFICIAL

La red neuronal se ha aplicado en muchas áreas, incluida la banca y las finanzas (Bakar, 2009). En la banca se ha utilizado para determinar la quiebra bancaria, series temporales, evaluación de préstamos, etc.

La idea de la red neuronal surgió por analogía con las neuronas que componen el cerebro humano. El funcionamiento de las células nerviosas para formar un modelo matemático fue estudiado por primera vez en 1943 por McCulloch y Pitts.

De manera muy resumida se puede decir que la red neuronal es un modelo simplificado que emula el modo en que el cerebro humano procesa la información. La red neuronal simula un número elevado de unidades de procesamiento interconectadas que asemejan neuronas (IBM SPSS neural networks, 2011). Las unidades de procesamiento se organizan en capas.

Generalmente la red neuronal tiene tres partes: una capa de entrada (campos de entrada), una o varias capas ocultas y una capa de salida (campos de destino). La red aprende examinando los registros individuales, generando una predicción para cada registro y realizando ajustes a las ponderaciones cuando realiza una predicción incorrecta. Este proceso se repite muchas veces y la red sigue mejorando sus predicciones hasta haber alcanzado uno o varios criterios de parada.




FIGURA 1. RELACIÓN ENTRE UNA RED NEURONAL Y UNA NEURONA.

Fuente: Adaptado de Roanboc (2016)

Actualmente existen muchos tipos de redes neuronales artificiales desarrollados para investigaciones muy diversas, pueden tener entrada binaria o continua o, según su algoritmo de aprendizaje pueden ser supervisadas o no supervisadas. En las redes supervisadas se destaca la red Hopfield y Perceptrón, en las no supervisadas se destacan la red ART y Mapas de Kohonen (Roanboc, 2016). Los resultados pronosticados de las redes supervisadas se pueden comparar con los valores conocidos de las variables dependientes.

Para el análisis de los datos se ha escogido una red neuronal perceptrón multicapa o de avance de una capa oculta, porque es especialmente útil en análisis predictivos y se

caracterizan por ser flexibles, potentes y de fácil uso. La metodología de esta red consiste en tener entradas x_1, \dots, x_i y salida y_k , cada entrada tiene su propio peso sináptico, luego los pesos se transfieren a la capa oculta, que consta de varias neuronas ocultas (Bakar, 2009). Cada neurona realiza una suma ponderada de las entradas y después pasa a una función de activación no lineal. La salida de la red está dada por la siguiente ecuación:

$$y_k = \varphi(\sum w_{ki}v_k) = \varphi(v) \text{ donde,}$$

$y_k \equiv$ salida de la red

$w_{ki} \equiv$ peso sináptico entre la salida de la neurona k y la entrada de la neurona i

$v_k = \sum w_{ki}v_k \equiv$ potencial de activación de la neurona i (entrada neta)

$\varphi(v) \equiv$ función de activación

La función de activación no lineal en la neurona generalmente se elige dentro de las funciones de forma, una de interpolación (smoothstep). En este estudio la Función sigmoide utilizada es $\varphi(v) = \frac{1}{1+e^{-v}}$.

3.3.3. ANÁLISIS FACTORIAL

El análisis factorial es una técnica estadística para reducir el número de variables que inicialmente se consideran en un análisis, a un número menor de factores. El análisis factorial supone que la varianza se puede dividir en dos tipos, común y única (Mateos, 2018). La varianza común es la cantidad de variación que se comparte entre las variables. Las variables que están altamente correlacionadas compartirán mucha variación, por lo que pocos factores explicarán gran parte de la varianza. Por el contrario, si las variables presentan baja correlación se necesitarán más factores para explicar la misma proporción de la varianza. La comunalidad es una definición de varianza común que varía entre 0 y 1. Los valores más cercanos a 1 sugieren que los factores extraídos explican más de la varianza de una variable individual.

La varianza única está formada por la varianza específica (capta la variabilidad propia de cada variable); y la varianza del error, proviene de errores de medición y sería básicamente todo lo que no se explica con la varianza común o específica. La varianza total está conformada por la varianza común y única.

Los pasos a seguir en un análisis factorial es la extracción de los factores (según el método escogido) y la rotación de los factores. Este último se utiliza para mejorar la interpretabilidad de los factores, al rotar aumenta la correlación de algunas variables con uno de los factores y disminuye con los otros factores. La rotación es opcional.

Para el análisis de los datos se escogió la extracción de los factores por análisis de componentes principales. El análisis de componentes principales forma combinaciones lineales no correlacionadas de las variables observadas. El primer componente tiene varianza máxima. Los componentes sucesivos explican porciones cada vez más pequeñas de la varianza y no están correlacionadas entre sí. El número de componentes que se obtienen o de factores es igual al número de variables iniciales. Es importante señalar que la suma de la varianza de las componentes es igual a la suma de las variables observadas. La diferencia entre las componentes y las variables observadas es que las componentes se calculan de forma que estén incorrelacionadas entre sí. Cuando las variables observadas no están tan correlacionadas entre sí, el análisis de componentes principales no tendría sentido, ya que los componentes coincidirían con las variables observadas (Mateos, 2018).

Como se ha mencionado las componentes principales se expresan como una combinación lineal de las variables observadas, y su notación matemática sería:

$$C_1 = c_{11}X_1 + c_{21}X_2 + \cdots + c_{p1}X_p$$

$$C_2 = c_{12}X_1 + c_{22}X_2 + \cdots + c_{p2}X_p$$

... ..

$$C_p = c_{1p}X_1 + c_{2p}X_2 + \cdots + c_{pp}X_p$$

Las X_1, \dots, X_p están tipificadas o expresadas en desviaciones respecto de su media muestral, la media c_i es cero.

Y la varianza para una componente i -ésima es: $V(C_i) = c_i'Vc_i$.

4. ANÁLISIS Y RESULTADOS

4.1.DESCRIPCIÓN DE LA MUESTRA

Para este estudio se consideran los bancos de licencia general, ya que las utilidades netas de los bancos de licencia internacional no son tan representativas como las de los bancos de licencia general, que además representan el 55% del Centro Bancario Internacional. Dado que el objetivo del análisis es conocer los factores determinantes de la rentabilidad de los bancos de Panamá, son los bancos de licencia general los que realmente realizan operaciones en Panamá.

De la lista de bancos publicada por la Superintendencia de Bancos de Panamá, se seleccionó una muestra de cuarenta y seis bancos para el año 2018. Para el período de 2015-2017 se utilizó una muestra de cuarenta y cuatro bancos, ya que no se consideran los bancos que iniciaron operaciones a partir del 2016. Para todos los períodos se excluyen los bancos que se encontraban en proceso de liquidación en ese momento. En la tabla 3 se incluyen los bancos y su clasificación según tipo de banca.

TABLA 3. LISTADO DE LOS BANCOS UTILIZADOS EN LA MUESTRA

Bancos	Fecha de Inicio de Operaciones	Tipo de banca
Allbank Corp.	Jul - 2012	Banca extranjera
Atlas Bank (Panamá), S.A.	Oct - 2017	Banca extranjera
BAC International Bank, Inc.	Mar - 1996	Banca extranjera
Banco Aliado, S.A.	Jul - 1992	Banca panameña privada
Banco Azteca (Panamá), S.A.	Mar - 2005	Banca extranjera
Banco Davivienda (Panamá), S.A.	Dic - 1966	Banca extranjera
Banco de Bogotá, S.A.	Jul - 2013	Banca extranjera
Banco del Pacífico (Panamá), S.A.	Jul - 1980	Banca extranjera
Banco Delta, S.A.	Jul - 2006	Banca panameña privada
Banco Ficohsa (Panamá), S.A.	May - 2011	Banca extranjera
Banco G&T Continental (Panamá), S.A.	Jul - 2008	Banca extranjera
Banco General, S.A.	Abr - 1955	Banca panameña privada
Banco Internacional de Costa Rica, S.A.	Sep - 1976	Banca extranjera
Banco La Hipotecaria, S.A.	Jun - 2010	Banca panameña privada
Banco Lafise Panamá S.A.	Mar - 2010	Banca extranjera
Banco Latinoamericano de Comercio Exterior, S.A. (BLADEX)	Ene - 1978	Banca extranjera
Banco Nacional de Panamá	Oct -1904	Banca oficial
Banco Panamá, S.A.	Abr - 2008	Banca panameña privada
Banco Panameño de la Vivienda, S.A.	Abr - 1981	Banca panameña privada
Banco Pichincha Panamá, S.A	May - 2005	Banca extranjera

Bancos	Fecha de Inicio de Operaciones	Tipo de banca
Banco Prival, S.A.	Mar - 2010	Banca panameña privada
Bancolombia, S.A.	Nov - 2012	Banca extranjera
BanESCO, S.A.	May - 1993	Banca extranjera
BANISI, S.A.	Mar - 2008	Banca extranjera
Banistmo, S.A.	Oct- 2013	Banca extranjera
Bank of China Limited	Jul - 1994	Banca extranjera
BBP Bank, S.A.	May - 2009	Banca extranjera
BCT Bank International	Mar - 1994	Banca extranjera
Bi-Bank, S.A.	Ene - 2016	Banca extranjera
Caja de Ahorros	Jul - 1934	Banca oficial
Canal Bank S.A.	Oct - 2014	Banca panameña privada
Capital Bank, Inc.	Ene - 2008	Banca panameña privada
Citibank, N.A. Sucursal Panamá	Ago - 1904	Banca extranjera
Credicorp Bank, S.A.	Jun - 1993	Banca panameña privada
FPB BANK, INC.	May - 2005	Banca extranjera
Global Bank Corporation	Jun - 1994	Banca panameña privada
Keb Hana Bank	Dic - 1980	Banca extranjera
Mega International Commercial Bank	Ago - 1974	Banca extranjera
Mercantil Banco, S.A.	Mar - 1978	Banca extranjera
Metrobank, S.A.	Sep - 1991	Banca panameña privada
MMG Bank Corporation	Mar - 2003	Banca panameña privada
Multibank, Inc.	May - 1990	Banca panameña privada
ST. Georges Bank & Company Inc.	Mar - 2002	Banca extranjera
The Bank of Nova Scotia	Nov - 1974	Banca extranjera
Towerbank International, Inc.	Oct - 1971	Banca panameña privada
Unibank, S. A.	Dic - 2010	Banca panameña privada

Fuente: Elaboración propia

A partir de los datos económicos financieros publicados de los bancos incluidos en la Tabla 3, se han calculado las diecinueve variables descritas en la Tabla 2. De los años 2015-2017 cuarenta y cuatro bancos estaban en operación normal y para el 2018 cuarenta y seis. Por lo que la muestra de 2015-2018 consta de un total de 178 observaciones.

4.2.RESULTADOS

Como se ha explicado con anterioridad, el análisis de los datos está estructurado en dos escenarios. En cada escenario el análisis principal es para el año 2018. El período de 2015-2017 se utiliza en el escenario 1 para compararlos con los resultados obtenidos en el año de estudio.

4.2.1. ESCENARIO 1: TODAS LAS VARIABLES INDEPENDIENTES

El escenario 1 incluye todas las variables independientes seleccionadas inicialmente para determinar los factores que inciden en la rentabilidad de los bancos. Las técnicas de análisis utilizadas en esta sección son el árbol de decisión CHAID y la red neuronal perceptrón multicapa. El análisis se realiza para el año 2018 y luego se compara con los años 2015-2017.

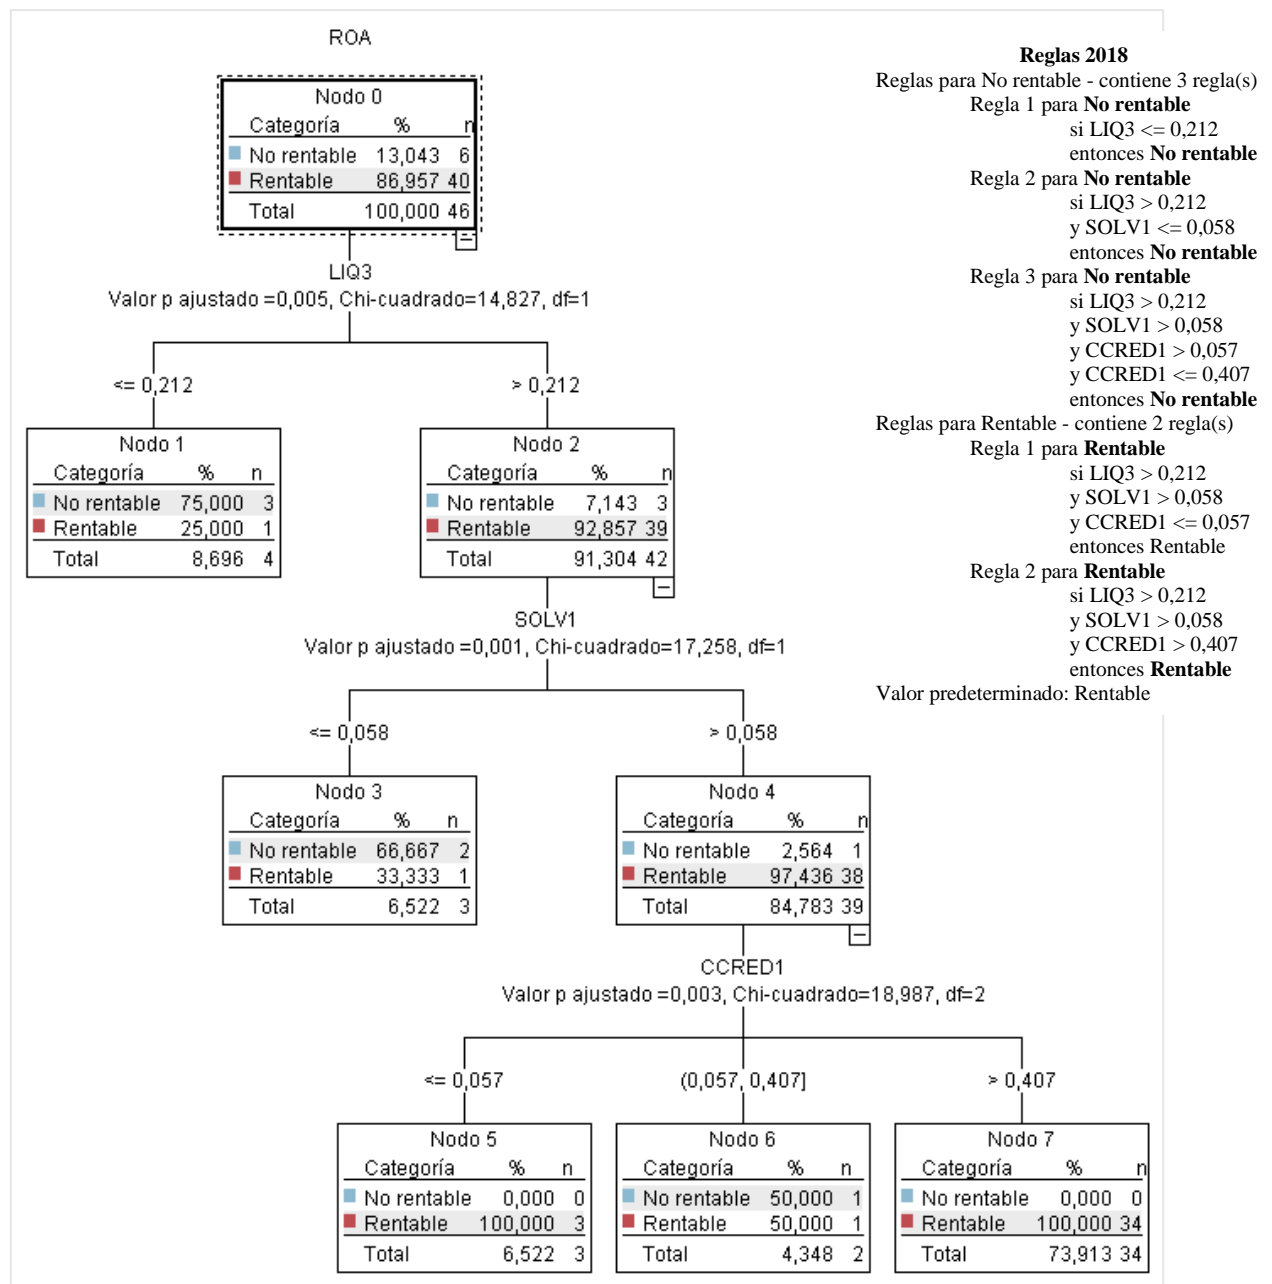
4.2.1.1.RESULTADOS DEL ÁRBOL DE DECISIÓN CHAID

El modelo generado por el árbol de decisión CHAID para el año 2018 utiliza tres variables para predecir la rentabilidad y tiene un poder predictivo 93,5% (Tabla 5). Los resultados, que se pueden apreciar en la Figura 3, muestran que la variable Liquidez 3 (Préstamos totales / Depósitos totales) es la que aporta mayor cantidad de información para predecir la rentabilidad bancaria, este indicador indica la cantidad de financiación de un préstamo por los depósitos. La variable Liquidez 3 se divide en dos nodos (1 y 2), el nodo 1 indica que si el banco presenta una liquidez menor a 0,212 el 75% de los bancos son no rentables. En el nodo 2 se observa que si la liquidez es mayor que 0,212 el 92,8% de los bancos son rentables.

El nodo 2 se vuelve a dividir en nodo 3 y nodo 4, ambos pertenecientes a la variable solvencia 1 (Patrimonio total / Activo total). La solvencia mide la capacidad que tiene el banco para sobrevivir a largo plazo, en concreto la relación del patrimonio y el activo indica que porcentaje del activo total está financiado por recursos propios. En el nodo 3 se observa que si la solvencia 1 es menor que 0,058 el 66,7% de los bancos son no rentables.

El nodo 4 se divide en tres nodos, nodo 5, nodo 6 y nodo 7, pertenecientes a la variable calidad del crédito 1 (Provisiones para préstamos / Préstamos vencido), que es la tercera variable en importancia para predecir la rentabilidad bancaria. Este indicador se utiliza para medir la relación entre los préstamos vencidos y las provisiones constituidas para cubrir dichos préstamos. Cabe señalar que la morosidad es un riesgo que amenaza la actividad bancaria y la rentabilidad se puede ver afectada por un aumento en los préstamos vencidos y no cobrados.

FIGURA 2. ÁRBOL DE DECISIÓN CHAID, 2018. ESCENARIO 1



Nota: LIQ3 = Préstamos totales / Depósitos totales; SOLV1 = Patrimonio total / Activo total;
CCRED1 = Provisiones para préstamos / préstamos vencidos
Fuente: Elaboración propia

TABLA 4. MODELOS ÁRBOLES DE DECISIÓN CHAID PARA LOS AÑOS 2015-2017. ESCENARIO 1

Modelo 2017	Modelo 2016
CCRED3 <= 0,012 [Modo: Rentable]	CCRED2 <= 0,015 [Modo: Rentable] => Rentable
LogPatrimo <= 4,233 [Modo: Rentable] => Rentable	CCRED2 > 0,015 and CCRED2 <= 0,017 [Modo: Rentable] => Rentable
LogPatrimo > 4,233 [Modo: Rentable] => Rentable	CCRED2 > 0,017 [Modo: No rentable] => No rentable
CCRED3 > 0,012 [Modo: No rentable]	
CCRED2 <= 0,026 [Modo: Rentable] => Rentable	
CCRED2 > 0,026 [Modo: No rentable] => No rentable	
Modelo 2015	
LogPatrimo <= 4,119 [Modo: No rentable] => No rentable	
LogPatrimo > 4,119 and LogPatrimo <= 4,445 [Modo: Rentable]	
LIQ3 <= 0,541 [Modo: No rentable] => No rentable	
LIQ3 > 0,541 [Modo: Rentable] => Rentable	
LogPatrimo > 4,445 and LogPatrimo <= 4,555 [Modo: No rentable] => No rentable	
LogPatrimo > 4,555 [Modo: Rentable] => Rentable	

Fuente: Elaboración propia

En la Tabla 4 se puede observar los modelos de árbol de decisión generados para los años 2015, 2016 y 2017. El modelo del 2017 utiliza tres variables predictoras, siendo las provisiones para préstamos entre activos totales (CCRED3) la de mayor importancia para determinar la rentabilidad bancaria. Le sigue en importancia las provisiones para préstamos entre los préstamos totales (CCRED2) y por último el logaritmo del patrimonio que es una variable para el control del tamaño. El modelo del 2016 es el más sencillo porque solo utiliza las provisiones para préstamos entre los préstamos totales. Por otro lado, el modelo del 2015 utiliza dos variables para predecir la rentabilidad bancaria, el logaritmo del patrimonio y los préstamos totales entre los depósitos totales.

Sin embargo, a pesar que cada modelo es diferente se puede concluir que las variables que más influyen en la rentabilidad son la calidad del crédito, la liquidez y el tamaño del banco.

En cuanto al poder predictivo de los modelos se puede apreciar en la tabla 5 que todos los modelos tienen una capacidad de predicción elevada. El que presenta una menor capacidad de predicción es el del año 2016 con un 90,91%. De hecho, es el modelo más sencillo ya que solo tiene una variable para predecir. El modelo del 2017 es el que presenta mayor poder predictivo con un 97,78% y con tres variables para realizar la predicción.

TABLA 5. CAPACIDAD DE PREDICCIÓN DEL ÁRBOL DE DECISIÓN CHAID PARA LOS AÑOS 2015-2018. ESCENARIO 1

	2018		2017		2016		2015	
Correctos	43	93,48%	43	97,78%	40	90,91%	41	93,18%
Erróneos	3	6,52%	1	2,22%	4	9,09%	3	6,82%
Total	46		44		44		44	

Fuente: Elaboración propia

La tabla 6 muestra la matriz de confusión de los modelos de árboles generados para los diferentes años, esta matriz ofrece una visión general de los errores que comete el algoritmo al clasificar las clases. El error que presentan los árboles es el error tipo 2 (falso negativo), en donde el algoritmo clasifica un banco como no rentable cuando es rentable. El error tipo 1 es mínimo y este es el peor error ya que el algoritmo clasifica un banco como rentable cuando realmente es no rentable.

TABLA 6. MATRIZ DE CONFUSIÓN ÁRBOL DE DECISIÓN CHAID. ESCENARIO 1 (2015-2018)

	2018		2017		2016		2015	
	No rentable	Rentable	No rentable	Rentable	No rentable	Rentable	No rentable	Rentable
No rentable	6	0	3	1	6	1	6	0
Rentable	3	37	0	41	3	34	3	35


Fuente: Elaboración propia

Podemos concluir, que el árbol de decisión logra con pocas variables predecir la rentabilidad bancaria con un buen nivel de aciertos, reduce el error tipo 1 (falsos positivos) y al utilizar pocas variables son modelos de fácil interpretación.

4.2.1.2.RESULTADOS DE LA RED NEURONAL

Para crear la red neuronal del año 2018 los datos fueron separados de manera aleatoria en 10% para reserva (sirve para validar el modelo) y 10% para prueba y 80% para entrenamiento de la red (Tabla 7), utiliza un porcentaje reducido para prueba y validación debido al número limitado de la muestra. La neurona tiene una capa oculta con cinco neuronas y catorce variables de entrada que corresponden a catorce de las diecinueve variables independientes, la red excluye del modelo las variables macroeconómicas (Figura 4).

FIGURA 3. RED NEURONAL PERCEPTRÓN MULTICAPA, 2018. ESCENARIO 1



Fuente: Elaboración propia

TABLA 7. RESUMEN DE LA MUESTRA DE LA RED NEURONAL, 2018. ESCENARIO 1

Tipo de muestra		N	Porcentaje
Muestra	Entrenamiento	36	80%
	Reserva	5	10%
	Prueba	5	10%
Válido		46	100.0%

Fuente: Elaboración propia

La precisión de los datos de entrenamiento es de 97,6% y de los datos de reserva es de 80%. Para probar la capacidad de la red, se introdujeron los datos de prueba en el modelo y se obtuvo como resultado una precisión del 95,7% (Tabla 8). El error asociado a la clasificación del modelo es del error tipo 2, por tanto, el algoritmo no presenta error del tipo 1 (Tabla 9). Se puede observar que la red logra clasificar bien los bancos no rentables cuando realmente no son rentables. Es necesario mencionar que el tamaño de la muestra es relativamente pequeña y esto puede estar influyendo en los modelos.

TABLA 8.CAPACIDAD DE PREDICCIÓN DE LA RED NEURONAL, 2018. ESCENARIO 1

	Entrenamiento	Reserva	Prueba
Correctos	97,6%	80,0%	95,7%
Erróneos	2,4%	20,0%	4,3%

Fuente: Elaboración propia


TABLA 9. MATRIZ DE CONFUSIÓN RED NEURONAL, 2018. ESCENARIO 1

	No rentable	Rentable
No rentable	6	0
Rentable	2	38

Fuente: Elaboración propia

En la Figura 5 se observa la importancia de las variables independientes, esta medida indica cuanto cambia el valor predicho por la red para diferentes valores de la variable independiente, las variables están ordenadas de mayor importancia a menos. Siendo las variables de solvencia, tamaño, liquidez y calidad del crédito las más importantes que utiliza la red para predecir la rentabilidad de los bancos.

FIGURA 4. IMPORTANCIA DE LAS VARIABLES INDEPENDIENTES. RED NEURONAL, 2018.
ESCENARIO 1



Fuente: Elaboración propia

Al comparar el modelo obtenido por la red neuronal perceptrón multicapa con el modelo obtenido con el árbol de decisión CHAID, se observa que en ambos modelos coincide la variable LIQ3, sin embargo, la red neuronal tiene un poder de predicción mayor. Y un error tipo 1 menor. Por lo que la red neuronal es más potente para predecir la rentabilidad bancaria.

TABLA 10. CAPACIDAD DE PREDICCIÓN DE LA RED NEURONAL PARA LOS AÑOS 2015-2017.
ESCENARIO 1

Año	Entrenamiento	Reserva	Prueba
2017	96,8%	66,7%	75,0%
2016	97,1%	100,0%	100,0%
2015	86,1%	80,0%	100,0%

Fuente: Elaboración propia

Para comparar los resultados de la red neural del 2018 con las del 2015, 2016 y 2017 se dejaron los mismos porcentajes de entrenamiento, prueba y reserva. Para todos los años las redes tienen una capa oculta con el mismo número de variables de entrada, solo cambia la importancia de las variables y el número de neuronas ocultas. En general se observa

que la red neuronal predice considerablemente bien la rentabilidad bancaria, a pesar de tener una muestra limitada de datos. El poder predictivo de la red se muestra en la Tabla 10. En los Anexos se puede observar la importancia de los predictores en cada modelo de los diferentes años y la red generada.

La red generada para el año 2015 resultó tener menos poder predictivo, sin embargo, en la matriz de confusión de la Tabla 11 muestra que el error del algoritmo se asocia más al tipo 2.

TABLA 11. MATRIZ DE CONFUSIÓN RED NEURONAL. 2015-2017. ESCENARIO 1

	2017		2016		2015	
	No rentable	Rentable	No rentable	Rentable	No rentable	Rentable
No rentable	3	0	6	1	4	2
Rentable	1	40	0	37	4	34

Fuente: Elaboración propia

El año 2016 presenta error tipo 1, pero este error solo representa el 2%, a pesar que clasifica un banco en rentable cuando realmente es no rentable, lo hace con un error mínimo.

4.2.2. ESCENARIO 2: APLICANDO ANÁLISIS FACTORIAL PARA REDUCIR EL NÚMERO DE VARIABLES

El escenario 2 consiste en reducir el número de variables por medio del análisis factorial con la metodología de componentes principales. Una vez que se obtengan el número de factores que explican la mayor varianza posible, los analizaremos mediante un árbol de decisión CHAID y una red neuronal perceptrón multicapa. Todo el análisis se realizará para el año 2018.

La técnica de análisis factorial es utilizada en muchos estudios de la rentabilidad bancaria porque permite identificar los principales indicadores que deben ser considerados para el análisis de la rentabilidad de las instituciones financieras (Alves, 2017).

Al utilizar esta metodología se busca identificar las variables más significativas para reducir su número y conseguir mejorar el análisis o lograr redes y árboles más sencillos y fáciles de interpretar.

4.2.2.1.RESULTADO DEL ANÁLISIS FACTORIAL

Como análisis previo al análisis factorial (AF) se analiza la matriz de correlaciones. En la matriz se aprecia que hay variables que no están muy correlacionadas (ver Anexo 6). Es importante que exista un alto grado de correlación ya que el modelo del análisis factorial se basa en las correlaciones para crear los factores. Existen otras medidas para determinar si es apropiado aplicar la técnica, entre ellas el cálculo del determinante de la matriz de correlaciones. El valor de este determinante resultó estar muy cercano a cero ($3,079716e-40$), lo que sugiere que se puede aplicar el AF porque un determinante cercano a cero indica alta multicolinealidad entre las variables. Aunque el determinante es casi cero, se sigue con la evaluación si es aceptable o no realizar el AF. En la Tabla 12, se observa el test de Bartlett que es útil para tamaños de muestras pequeños y busca contrastar la hipótesis nula que no existe multicolinealidad entre las variables, en nuestro caso el valor-p es menor que 0,5 por lo que se rechaza la hipótesis nula y se confirma que existe multicolinealidad entre las variables. Por último, se analiza el KMO (Kaiser-Meyer-Olkin), que es una medida de suficiencia o adecuación de la muestra. Si es menor que 0,5 no debe realizarse el AF. En concreto, para este estudio el KMO se situó en 0,5 que indica que se puede realizar el AF, pero se recomienda revisar las variables o excluir algunas para mejorar el AF o la agrupación entre las variables. En consecuencia, la evaluación previa sugiere que se puede hacer un AF, solo que no es seguro que se obtengan resultados satisfactorios.

TABLA 12. PRUEBAS ESTADÍSTICAS PARA ANTES DE EMPEZAR EL AF

Determinante	Test de Bartlett	KMO
3,079716e-40	K-squared = 37.896, df = 18, p-value < 2.2e-16	0,5

Fuente: Elaboración propia

Justificada la posibilidad de realizar el AF, se procede a crear los factores. Los resultados se muestran a continuación.

Las comunalidades obtenidas en el modelo se muestran en la Tabla 13, donde se observa que quince de las diecinueve variables tienen comunalidades superiores a 0,8. Solo una variable presentó una comunalidad relativamente baja con un 0,289. Sin embargo, el promedio de comunalidades es de un 0,84 lo que indica que las variables son explicadas adecuadamente por el modelo.

TABLA 13. COMUNALIDADES ANÁLISIS FACTORIAL

Variables	Comunalidad
LIQ1	0,643
LIQ2	0,817
LIQ3	0,704
CCRED1	0,289
CCRED2	0,827
CCRED3	0,874
SOLV1	0,906
SOLV2	0,851
RENT1	0,979
RENT2	0,980
Eficiencia	0,554
LogActivo	0,964
LogPatrimo	0,915
LogIngreso	0,946
Balanza	0,936
IPC	0,940
PIB	0,930
Desempleo	0,949
LogPercapita	0,975

Fuente: Elaboración propia

Tomando como referencia los autovalores con valores propios mayores a la unidad, se redujeron las variables iniciales a siete factores o componentes, que explican un 84,1% de la varianza. En la Tabla 14 se muestra la varianza total explicada de los ocho primeros componentes y el porcentaje que representan de varianza.

TABLA 14. VARIANZA TOTAL EXPLICADA

Componente	Autovalores iniciales			Sumas de cargas al cuadrado de la extracción		
	Total	% de varianza	% acumulado	Total	% de varianza	% acumulado
1	4,164	21,916	21,916	4,164	21,916	21,916
2	3,410	17,947	39,863	3,410	17,947	39,863
3	2,458	12,938	52,801	2,458	12,938	52,801
4	1,837	9,668	62,469	1,837	9,668	62,469
5	1,625	8,551	71,020	1,625	8,551	71,020
6	1,434	7,545	78,565	1,434	7,545	78,565
7	1,053	5,541	84,106	1,053	5,541	84,106
8	0,993	5,224	89,331			

Fuente: Elaboración propia

Para algunas variables el agrupamiento con los factores no era muy claro, y se procedió a rotar los factores para facilitar la interpretación. Se utilizó el método varimax, porque hace que cada factor mantenga correlaciones altas con pocas variables y bajas correlaciones con el resto de las variables. Este criterio tiene la particularidad de mantener la varianza total explicada, pero varía la varianza de cada factor.

En la Tabla 15 se muestran las variables que están más correlacionadas con los factores obtenidos.

TABLA 15. RESULTADO DE LAS CARGAS FACTORIALES ROTADAS

Componentes	Variable	Carga factorial	Denominación
1	Desempleo	0,973	Macroeconómicas 1
	LogPerCapita	0,955	
	IPC	0,950	
2	LogActivo	0,930	Tamaño
	LogIngreso	0,924	
	LogPatrimo	0,819	
3	LIQ3	0,832	Liquidez
	LIQ2	0,814	
	LIQ1	-0,746	
4	RENT1	0,975	Rentabilidad
	RENT2	0,961	
5	CCRED3	0,906	Crédito- Eficiencia
	CCRED2	0,831	
	Eficiencia	-0,401	

Componentes	Variable	Carga factorial	Denominación
6	SOLV2	0,901	Solvencia
	SOLV1	0,874	
7	Balanza	0,934	Macroecoómicas-Crédito
	PIB	-0,690	
	CCRED1	0,411	

Fuente: Elaboración propia

Interpretación de los factores

El primer factor, es el que más ayuda a explicar la varianza, con un 21,9%, y está más correlacionado con tres de las cinco variables macroeconómicas: Estas variables son el desempleo, la renta per cápita y la inflación. Además, la correlación que presentan estas variables con el factor es positiva. A este factor lo podemos llamar **MACROECONÓMICA 1** y al tener la primera posición en el conjunto de componentes, indica que son las variables con más correlación y su importancia para el AF.

El segundo factor explica un 19,7% de la varianza total y está más correlacionado las variables de control que se refieren al tamaño (activo, patrimonio ingresos netos). Llamaremos al factor 2 **TAMAÑO** y es lógica su consideración ya que hay varios estudios, entre ellos el estudio de Booyens (2016), que plantean que cuanto mayor sea el tamaño del banco mayor será su rentabilidad.

El tercer factor, lo llamaremos **LIQUIDEZ**, explica el 12,9% de la varianza total explicada por los factores. La liquidez 1 (relación de los activos líquidos con el activo total) se correlaciona negativamente, mientras que los otros dos indicadores presentan una correlación positiva.

El cuarto factor, representa la **RENTABILIDAD**, explica un 9,7% de la varianza total. Ambos ratios miden la rentabilidad más propia de la actividad bancaria y están relacionados directamente con el control de los gastos. Es decir, si el banco no controla de manera adecuada sus gastos se supone una disminución en sus utilidades.

El quinto factor se relaciona con las variables de calidad del crédito 2 (mide la cobertura que tiene el banco sobre los préstamos vencidos) y calidad del crédito 3 (mide la calidad del activo). También incluye la variable eficiencia (está representada por la relación de los costes entre los ingresos). Hay que tener en cuenta que, en general, esta variable no presenta una correlación muy buena con ningún factor. Sin embargo, con el factor cinco

es con la que tiene más correlación, siendo esta negativa. Este factor explica el 8,5% de la varianza total y representa el **CRÉDITO-EFICIENCIA**.

El sexto factor explica el 7,5% de la varianza total y está más correlacionado con los indicadores de **SOLVENCIA**. Como ya se mencionó los indicadores de solvencia o ratio de endeudamiento reflejan la capacidad del banco para soportar posibles pérdidas o posibles disminuciones en el valor de sus activos.

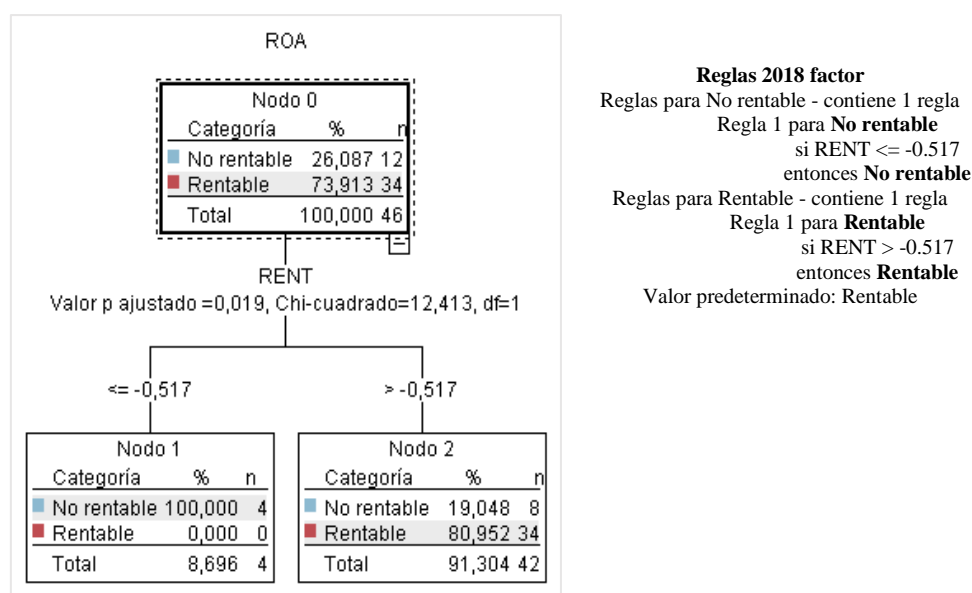
El séptimo factor tiene dos variables macroeconómicas que son el saldo de la balanza corriente y el PIB que está relacionada negativamente con el factor. También incluye una variable de calidad del crédito (CCRED1), que sirve para medir la insolvencia, ya que cuanto más grande sea el ratio, indica que la entidad puede hacer frente a más impagos, sin que estos repercutan en sus resultados. El porcentaje que explica de la varianza total es de un 5,5%. El nombre para el factor será **MACROECONÓMICAS-CRÉDITO**.

4.2.2.2.RESULTADO DEL ÁRBOL DE DECISIÓN CHAID

Con los factores obtenidos en el paso anterior, se efectuó un análisis por árboles de decisión con la metodología CHAID. El análisis solo se lleva a cabo para el año 2018, con la finalidad de determinar las variables que más influyen en la rentabilidad bancaria para el 2018 y compararla con los resultados obtenidos en el escenario 1 para el mismo período.

En la Figura 6 se muestran los resultados obtenidos por el análisis factorial – árbol de decisión CHAID. El árbol solo considera el factor relacionado con la **RENTABILIDAD** para predecir la rentabilidad bancaria medida por el ROA. El árbol solo tiene dos nodos. El nodo 1 indica que si el factor representado por la **RENTABILIDAD**, es menor que - 0,517 no será un banco rentable. Por el contrario, el nodo 2 indica que, si obtienes una puntuación mayor, hay un 80,9% de probabilidad de ser rentable. El factor **RENTABILIDAD** representado por los gastos generales, los ingresos por intereses, las pérdidas por deterioros de activos financieros, ayuda a medir la rentabilidad de los ingresos recurrentes propios de la actividad bancaria.

FIGURA 5. RESULTADO ÁRBOL DE DECISIÓN CHAID CON LOS FACTORES, 2018. ESCENARIO 2



Fuente: Elaboración propia

En la Tabla 16 se observa que la capacidad de predicción del árbol es de 82,6%, un porcentaje menor que el obtenido en el modelo del árbol del escenario 1 (93,5%). Sin embargo, hay que recordar que el árbol del escenario 1 utiliza tres variables para predecir la rentabilidad bancaria, mientras que el árbol del escenario 2 utiliza un factor (que incluye dos variables).

TABLA 16. CAPACIDAD DE PREDICCIÓN DEL ÁRBOL CHAID - FACTOR. ESCENARIO 2

	Frecuencia	Porcentaje
Correctos	38	82,61%
Erróneos	8	17,39%
Total	46	

Fuente: Elaboración propia

El error de predicción del árbol con factor es de 17,4% (Tabla 16), y este error está más relacionado con el tipo 1 (falsos positivos), es decir, el algoritmo detecta un banco rentable cuando realmente es no rentable (Tabla 17). El error tipo 1 es el peor error por

lo que el árbol generado con los factores tiene menos poder de predicción y aumenta el peor error, en comparación al árbol del escenario 1.

TABLA 17. MATRIZ DE CONFUSIÓN MODELO CHAID - FACTOR. ESCENARIO 2

	No rentable	Rentable
No rentable	4	8
Rentable	0	34

Fuente: Elaboración propia

A parte de la precisión del modelo y la matriz de confusión se utiliza el coeficiente de Gini y área bajo la curva (AUC, por sus siglas en inglés) para comparar la eficacia del modelo del escenario 1 con el escenario 2.

El AUC se calcula como el área bajo una curva ROC (Receiver Operator Characteristic) que es la representación escalar del rendimiento esperado por un clasificador. El índice de Gini está estrechamente relacionado con el AUC, de hecho, se calcula como dos veces el área comprometida entre la curva ROC y la diagonal. Ambos coeficientes están entre 0 y 1, y cuanto mayor es el número mejor es el clasificador. En la tabla 18, se puede observar los resultados de ambos coeficientes para los dos modelos.

TABLA 18. MÉTRICAS DE EVALUACIÓN ESCENARIO 1 Y 2

Modelo	AUC	Gini
CHAID escenario 1	0,971	0,942
CHAID escenario 2	0,667	0,333

Fuente: Elaboración propia

El árbol del escenario 1 sigue siendo mejor para predecir la rentabilidad bancaria, ya que al reducir el número de variables el árbol del escenario 2 es menos preciso y tiene un error


de clasificación del tipo 1 (falsos positivos) mayor, es decir, el banco es no rentable pero el algoritmo detecta que el banco es rentable.

4.2.2.3.RESULTADO DE LA RED NEURONAL

Al igual que con el árbol de decisión, también se procedió a analizar los factores obtenidos con una red neuronal perceptrón multicapa. Con los mismos parámetros que la calculada en el escenario 1, y solo para el año 2018.

A continuación, se exponen los resultados obtenidos.

FIGURA 6. RED NEURONAL – FACTOR, 2018. ESCENARIO 2



Fuente: Elaboración propia

TABLA 19. IMPORTANCIA DE LOS FACTORES EN LA RED NEURONA. ESCENARIO 2

Factores	Importancia
Solvencia	0,0677
Macroeconómicas 1	0,08
Crédito- eficiencia	0,1116

Factores	Importancia
Liquidez	0,1183
Macroeconómicas-crédito	0,1985
Tamaño	0,2057
Rentabilidad	0,2182

Fuente: Elaboración propia

TABLA 20. CAPACIDAD DE PREDICCIÓN DE LA RED NEURONAL - FACTOR. ESCENARIO 2

	Frecuencia	Porcentaje
Correctos	39	84.78%
Erróneos	7	15.22%
Total	46	

Fuente: Elaboración propia

TABLA 21. MATRIZ DE CONFUSIÓN RED NEURONAL - FACTOR. ESCENARIO 2

	No rentable	Rentable
No rentable	5	7
Rentable	0	34

Fuente: Elaboración propia

En los resultados que acabamos de mostrar, se observa que la red neuronal tiene una capa oculta con dos neuronas. Tiene un poder de predicción de 85% (la muestra de entrenamiento). En la Tabla 19 se puede apreciar la importancia de los factores en la red: el factor más importante es el relacionado con rentabilidad (mismo que utiliza el árbol CHAID con factor), le sigue el factor relacionado con el tamaño y, por último, el factor de variables macroeconómicas-crédito, estas tres tienen una importancia de 62%.

Las variables macroeconómicas son el PIB (que tiene una influencia negativa), la balanza de pagos y la de crédito (provisiones / activo total).

Como en el caso del árbol con factor, la red neuronal con factor aumenta el error tipo 1, que es el peor. En comparación a la red calculada con todas las variables independientes en el escenario 1, la red del escenario 1 tiene mayor poder predictivo (97,6%) y un AUC y Gini mayor (Tabla 22), además que no tiene error tipo 1.

TABLA 22. MÉTRICA DE EVALUACIÓN RED NEURONAL ESCENARIO 1 Y 2

Modelo red neuronal	AUC	Gini
Escenario 1	0,825	0,65
Escenario 2	0,814	0,627

Fuente: Elaboración propia

4.2.3. RESUMEN DE RESULTADOS

En la Tabla 23 se resume el porcentaje de precisión de los modelos generados en ambos escenarios.

TABLA 23. RESUMEN DE PRECISIÓN DE LOS MODELOS

Modelo	Porcentaje
Árbol CHAID escenario 1	93,48%
Árbol CHAID escenario 2	97,6%*
Red neuronal escenario 1	82,61%
Red neuronal escenario 2	84,78%*

*Rendimiento obtenido de los datos de entrenamiento

Fuente: Elaboración propia

En la tabla mostrada anteriormente, se puede observar que la red neuronal tiene mejor porcentaje de acierto para predecir a rentabilidad bancaria, siendo aún mejor la generada en el escenario 1 (con todas las variables independientes). A pesar que los modelos que utilizan los factores (escenario 2) son más sencillos y simples, su error tipo 1 (es peor), por lo que el algoritmo no tiene buena detención de bancos no rentables.

En base a los resultados obtenidos en el escenario 1 las variables que más influyen en la rentabilidad son las de calidad de crédito (o riesgo de crédito), en concreto la que mide la cantidad de crédito que ha sido cubierto sin que todavía caiga en incumplimiento, las variables de control tamaño y las de liquidez. Dentro de esta última categoría la que más se repite es la que relaciona los préstamos con los depósitos, es decir, el banco cuanto más se financia con los depósitos para conceder préstamos es más rentable. Finalmente, la última que más se repite es relativa a la solvencia, en concreto, la que relaciona el patrimonio entre los activos: cuanto más alta sea su medida más cubierto está del riesgo y más rentable será el banco.

5. CONCLUSIONES

Los métodos de árboles de decisión y redes neuronales no requieren ninguna hipótesis sobre la distribución de los datos y, además, son robustos aún con valores atípicos. Su uso en las finanzas se está difundiendo mucho, ya que son muy amplias sus posibles aplicaciones dadas las características que presentan las series de datos en finanzas. Además, son fáciles de aplicar y proporcionan buenos resultados. Estas técnicas se pueden combinar con otras técnicas estadísticas para obtener mejores resultados.

Con ambas técnicas se obtuvieron buenos resultados. En concreto, la que mejor resultados generó fue la red neuronal. Sin embargo, los árboles de decisión son más fáciles de interpretar, por lo que se podría en futuros estudios aplicar primeramente las redes neuronales y luego aplicar a las variables más importantes reveladas por las redes, los árboles de decisión para facilitar la interpretación de los resultados.

Con el análisis factorial en componentes principales no se obtuvieron los resultados deseados ya que se esperaba una mayor correlación entre las variables y que al agruparlas la predicción de la rentabilidad fuera mejor. Es cierto que al ser ratios financieros están correlacionados, pero al estar divididos en liquidez, solvencia y calidad del crédito, se reduce la correlación entre ellos. Sería interesante, por tanto, en futuras investigaciones ampliar el número de ratios financieros o variables internas de las operaciones bancarias y sacar del estudio las variables que no están muy correlacionadas o ir introduciendo poco a poco las variables al modelo factorial hasta que se obtengan mejores resultados. Cabe recordar que se obtuvieron siete factores que explicaban más del 80% de la varianza, pero al aplicar las técnicas de predicción no se obtuvieron resultados tan robustos.

Por otro lado, los resultados de los modelos indicaron que las variables macroeconómicas no tienen un efecto significativo para los modelos. De hecho, al incluir estas variables se esperaba que por lo menos el PIB tuviera un efecto negativo en la rentabilidad, al igual que ocurre en los resultados de los estudios considerados para iniciar este trabajo. También se esperaba que la eficiencia fuera un determinante en la rentabilidad de los bancos. Sin embargo, los modelos obtenidos no utilizan la eficiencia para predecir la rentabilidad, por lo tanto, los resultados obtenidos van en contra de este supuesto, señalando que un banco eficiente no necesariamente sería rentable o un banco rentable no necesariamente será eficiente.

Las variables obtenidas como determinantes de la rentabilidad están acorde con los resultados esperados, y son, solvencia, liquidez, calidad del crédito y el tamaño.

Se puede concluir que, para la variable calidad del crédito, cuantas más provisiones tenga que constituir un banco por deterioro de en su cartera de crédito, será menos rentable. Además, cuanto mayor volumen de negocio y tamaño tenga el banco, será más rentable. En cuanto a los resultados obtenidos para la variable liquidez, un banco será más rentable, si los depósitos que capta los utiliza para prestar dinero. Finalmente, en cuanto a la variable solvencia, se concluye que, si el banco mantiene una buena gestión del riesgo de crédito podrá mantener la rentabilidad.

Es necesario mencionar que la mayor dificultad encontrada para realizar el estudio fue calcular los indicadores financieros adecuados y que se ajustaran a las definiciones de cuentas que se utilizan en la Superintendencia de Bancos de Panamá. Al no contar con un estudio empírico que analizara la rentabilidad de los bancos panameños, no se tenía una idea previa de cómo es el comportamiento de la rentabilidad y las variables que serían determinantes.

Una de las debilidades en el estudio fue que se cuenta con pocas observaciones lo que puede distorsionar los resultados, a pesar que los resultados son válidos y satisfactorios, y se lograron los objetivos planteados. Por lo tanto, podríamos considerar este estudio como un estudio previo o base para futuras investigaciones.

Al ser un estudio previo para futuros análisis para determinar la rentabilidad de los bancos panameños, en posteriores estudios se pueden realizar otras técnicas estadísticas, ampliar la base de datos con más períodos teniendo en cuenta el efecto de los diferentes años. Además, se pueden incluir otras variables de predicción como el ratio de concentración de los bancos en el mercado, el crecimiento de la actividad bancaria, o alguna otra variable macroeconómica que sí pueda explicar la variación de la rentabilidad bancaria. Por otro lado, se puede considerar ampliar el estudio a todo el Centro Bancario Internacional, como ya se mencionó, utilizando otra técnica o la mismas utilizados en este estudio, redes neuronales y árboles de decisión y que resultaron ser muy buenas para predecir la rentabilidad bancaria del sistema bancario panameño.

Otro aspecto que se puede ampliar está relacionado con la variable dependiente, la rentabilidad. En el estudio se comprobó que la mayoría de los bancos tienen una rentabilidad positiva y aunque ésta fuese una rentabilidad baja, se le incluyó como banco

rentable. Sin embargo, para otros estudios sobre el tema se puede hacer la agrupación de los bancos rentables y no rentables tomando en cuenta otros parámetros, para tener una muestra más grande de bancos no rentables.

6. REFERENCIAS

- Albertazzi, U., & Gambacorta, L. (2006). Bank profitability and the business cycle number 601. *Banca D'Italia*, (601), 1-39.
- Alexiou, C., & Sofoklis, V. (2009). Determinants of bank profitability: Evidence from the Greek banking sector. *Ekonomski Anali*, 54 (182), 93-118.
- Alves e Souza, J., Mendonça, D. J., de Benedicto, G. C., & Carvalho, F. d. M. (2017). Application of factor analysis to identify the main indicators of economic and financial performance in banking financial institutions. *Revista Catarinense Da Ciência Contábil*, 16 (47), 26-41.
- Bakar, N. M. A., & Tahir, I. M. (2009). Applying multiple linear regression and neural network to predict bank performance. *International Business Research*, 2 (4), 8.
- Berlanga Silvente, V., Rubio Hurtado, M. J., & Vilá Baños, R. (2013). Cómo aplicar árboles de decisión en SPSS. *Revista D' Innovació i Recerca En Educació*, 6(1), 67, 75-77.
- Bernal Turnes, P., Ampudia Fernández, J., & Torres Pruñonosa, J. (2010). Análisis de la estructura financiera de entidades bancarias. *Ediciones La Coria*, 301, 2-6.
- Blanco González, A., Mercado Idoeta, C., & Bernal Turnes, P. (2007). Evaluación y modelización de la estructura financiera de entidades financiera para medir su rendimiento. *Asociación Europea de Dirección y Economía de Empresa* 1(20), 86-88.
- Blanco Mendialdua, A. (2015). *Gestión de entidades financieras: Un enfoque práctico de la gestión bancaria actual*. Madrid: ESIC. 230-232.
- Booyens, M., Nayagar, K., & L le Roux, C. (2016). An empirical analysis of South African bank profitability. *Economies*, 6(3), 1-10.
- Davydenko, A. (2010). Determinants of bank profitability in Ukraine. *Undergraduate Economic Review*, 7(2), 32.
- Dirección de Estudios Financieros. (2017). *Informe de estabilidad financiera*. Panamá: Superintendencia de Bancos de Panamá

- Fernández, J. A., Bejarano Vázquez, V., & Vicente Virsela, J. A. (2013). *Métodos de Predicción de Riesgos de Entidades de Depósito en España 160b*.
- Fuentes García, D. (2016). *Determinantes de la rentabilidad bancaria española antes y después de la crisis financiera*. Alcalá de Henares: Universidad de Alcalá, Servicio de Publicaciones.
- González Pérez, A. L., Correa Rodríguez, A., & Acosta Medina, M. (2002). Factores determinantes de la rentabilidad financiera de las PYMES. *Revista Española De Financiación Y Contabilidad*, 31(112), 395-429.
- IBM. (2011). *IBM SPSS neural networks 20*. Estados Unidos: Copyright IBM Corporation. 4, 44-47
- Ley orgánica del banco nacional de panamá, (2017). Retrieved from <http://www.bibliothek.uni-regensburg.de/ezeit/?2407089>.
- López Pascual, J., & Sebastián González, A. (2008). *Gestión bancaria: Factores claves en un entorno competitivo* (3ª ed. ed.). Madrid: McGraw Hill. 195-2008.
- Magerman, D. M. (1995b). Statistical decision-tree models for parsing. *Proceedings of the 33rd Annual Meeting on Association for Computational Linguistics*, 276–283.
- Mallo, P. E., Artola, M. A., Zanfrillo, A. I., Morettini, M., Galante, M. J., Busetto, A. R., & Pascual, M. E. (2007). *Un aporte al análisis de la rentabilidad de entidades financieras de la República Argentina*. Congreso de la sociedad internacional de gestión y economía fuzzy. 6-8.
- Mateos, Gregoria, (2018). Análisis factorial. Apuntes de la asignatura Estadística Actuarial III, del Máster en Ciencias Actariales y Financieras, Facultad de Ciencias Económicas y Empresariales, Universidad Complutense de Madrid. Curso académico 2018/2019.
- Pérez Marqués, M. (2014). *Minería de datos a través de ejemplos*. Madrid: RC Libros. 232-285.
- Petria, N., Capraru, B., & Ilnatov, I. (2015). Determinants of banks' profitability: Evidence from EU 27 banking systems. *Procedia Economics and Finance*, 20, 518-524.

Normativa bancaria de Panamá U.S.C. (2017).

Unidad de Monitoreo y Análisis de la Competitividad (UMAC) del Centro Nacional de Competitividad (CNC) Panamá. (2014). Competitividad al día no. 193 - importancia del sector bancario para la competitividad panameña, (193), 2.

REFERENCIAS ELECTRÓNICAS

Banco de España. Definición de rentabilidad. Recuperado el 10 de abril de 2019, de https://app.bde.es/atz_www/jsp/webSearch.jsp?acceso=bde&idioma=es&tipo=glosarioGen&T5=RELEVANCE&T1=rentabilidad.

Consejo de Coordinación Financiera. Sistema financiero panameño. Recuperado el 20 de marzo de 2019, de <https://www.ccf.gob.pa/resena.html>.

Diario de actualidad argentino Infobae. ¿Qué son los panama papers?. Recuperado el 14 de junio de 2019, de <https://www.infobae.com/politica/2019/04/09/que-son-los-panama-papers/>.

Instituto Nacional de Estadística y Censo de Panamá. Variables macroeconómicas. Recuperado el 03 de marzo de 2019, de <https://www.contraloria.gob.pa/inec/>.

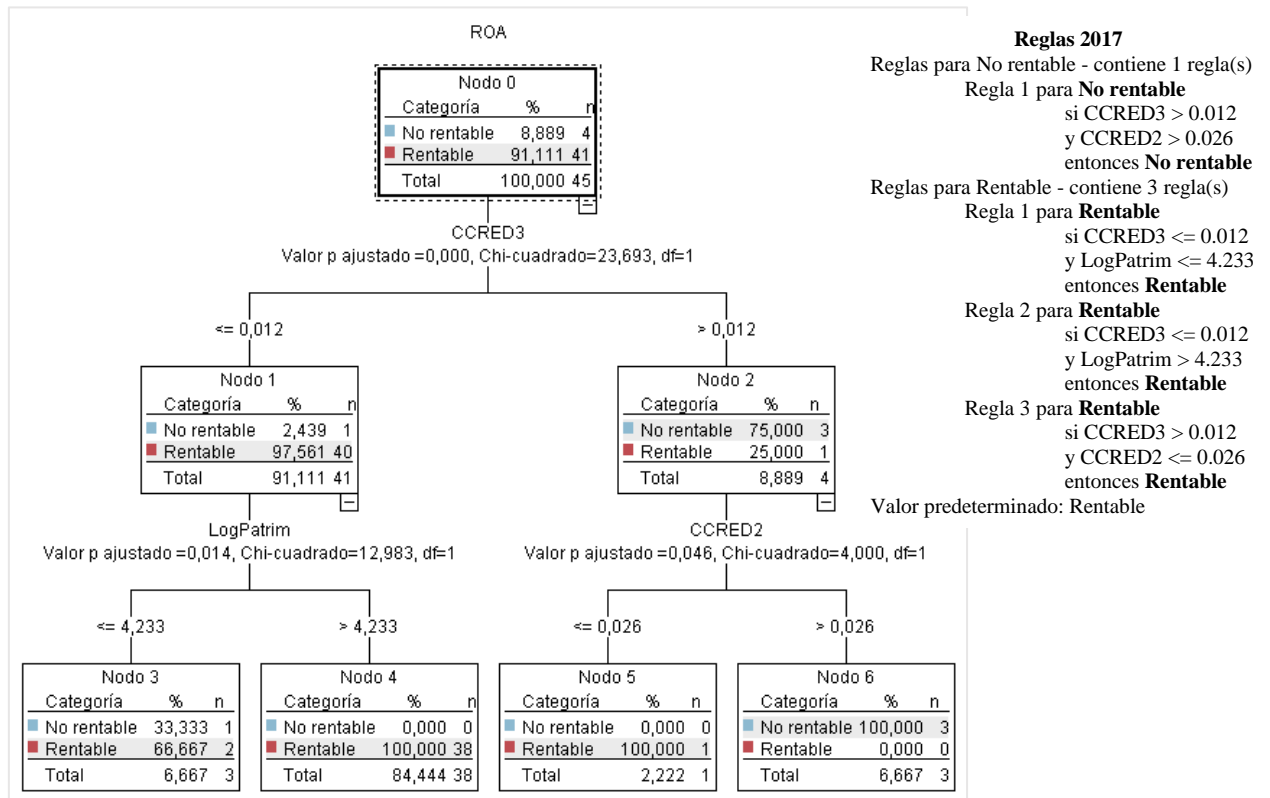
Roanboc. (2016). Prototipo de una red neuronal artificial con arquitectura dinámica basada en el proceso de neurogénesis de redes neuronales maduras. Retrieved from <https://roanboc.wordpress.com/2016/11/20/prototipo-de-una-red-neuronal-artificial-con-arquitectura-dinamica-basada-en-el-proceso-de-neurogenesis-de-redes-neuronales-maduras/>.

Superintendencia de Bancos de Panamá. Estados financieros de los bancos, informes financieros y estadísticas publicadas. Recuperado el 21 de mayo de 2019, de <https://www.superbancos.gob.pa/>.

7. ANEXOS

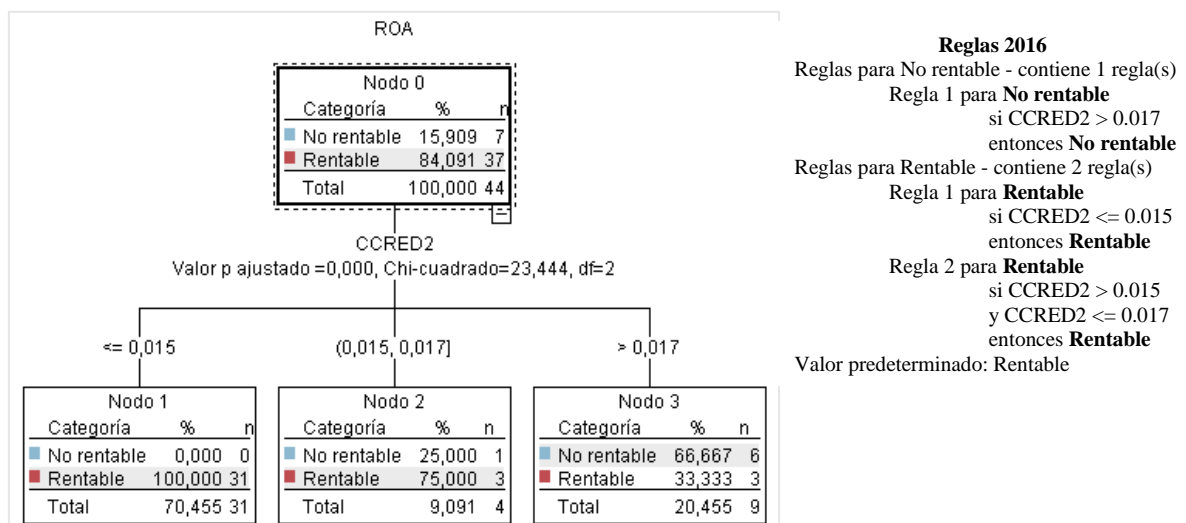
ANEXO 1. ÁRBOLES DE DECISIÓN CHAID. 2015-2017. ESCENARIO 1

ÁRBOL CHAID 2017 Y CONJUNTO DE REGLAS



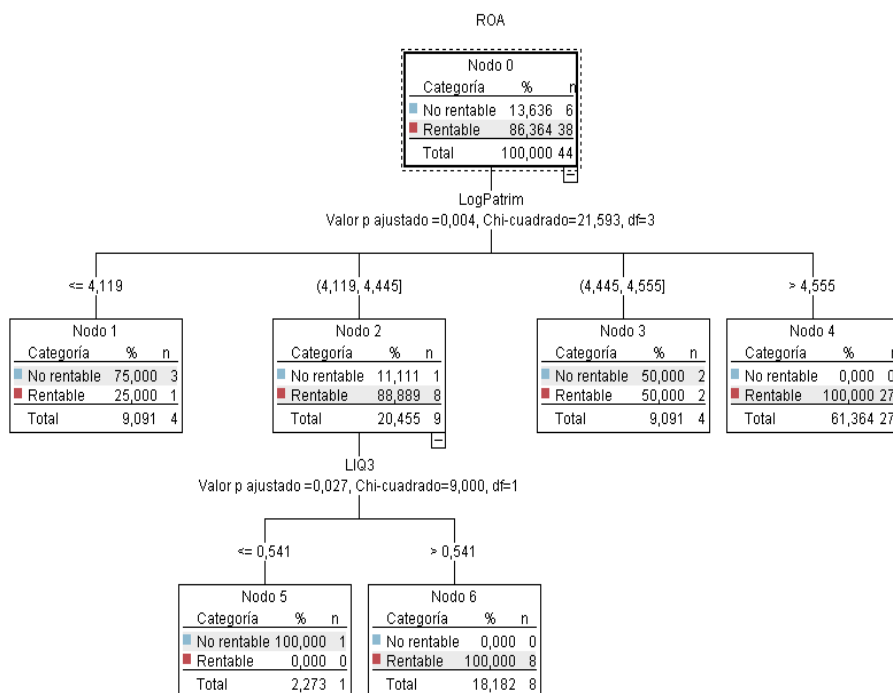
Fuente: Elaboración propia

ÁRBOL CHAID 2016 Y CONJUNTO DE REGLAS



Fuente: Elaboración propia

ÁRBOL CHAID 2015 Y CONJUNTO DE REGLAS



Reglas 2015

ara No rentable - contiene 3 regla(s)

Regla 1 para **No rentable**
si LogPatrim ≤ 4.119
entonces **No rentable**

Regla 2 para **No rentable**
si LogPatrim > 4.119
y LogPatrim ≤ 4.445
y LIQ3 ≤ 0.541
entonces **No rentable**

Regla 3 para **No rentable**
si LogPatrim > 4.445
y LogPatrim ≤ 4.555
entonces **No rentable**

ara Rentable - contiene 2 regla(s)

Regla 1 para **Rentable**
si LogPatrim > 4.119
y LogPatrim ≤ 4.445
y LIQ3 > 0.541
entonces **Rentable**

Regla 2 para **Rentable**
si LogPatrim > 4.555
entonces **Rentable**

¿determinado: Rentable

Fuente: Elaboración propia


ANEXO 2. IMPORTANCIA DE LA VARIABLES INDEPENDIENTES, ÁRBOL CHAID. 2015-2018

Variables	2018	2017	2016	2015
LogPatrimo	-	0,20	-	0,87
CCRED3	-	0,40	-	-
CCRED2	-	0,40	1,00	-
LIQ3	0,25	-	-	0,13
SOLV1	0,41	-	-	-
CCRED1	0,33	-	-	-

Fuente: Elaboración propia

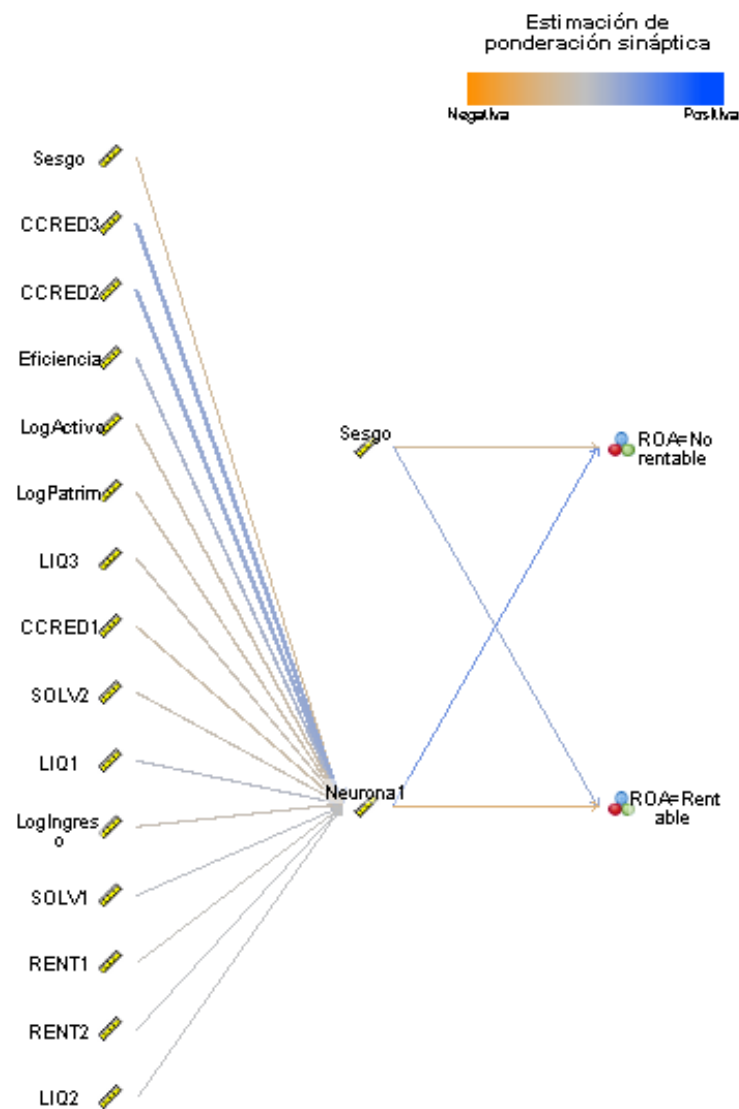
ANEXO 3. REDES NEURONALES. 2015-2017 - ESCENARIO 1

RED NEURONAL. 2017 – ESCENARIO 1




Fuente: Elaboración propia

RED NEURONAL. 2016 – ESCENARIO 1



Fuente: Elaboración propia

RED NEURONAL. 2015 – ESCENARIO 1



Fuente: Elaboración propia

ANEXO 4. IMPORTANCIA DE LAS VARIABLES INDEPENDIENTES

Variables	2017	2016	2015
LIQ1	0,038	0,045	0,132
LIQ2	0,037	0,079	0,063
LIQ3	0,095	0,106	0,025
CCRED1	0,015	0,086	0,009
CCRED2	0,198	0,220	0,070
CCRED3	0,047	0,193	0,069
SOLV1	0,170	0,002	0,057
SOLV2	0,032	0,003	0,012
RENT1	0,024	0,001	0,099
RENT2	0,141	0,011	0,030
Eficiencia	0,029	0,053	0,030
LogActivo	0,013	0,095	0,127
LogPatrim	0,036	0,064	0,129
LogIngreso	0,124	0,041	0,148

Fuente: Elaboración propia

ANEXO 5. CÓDIGO R PARA DETERMINAR SI ES ADECUADO APLICAR AF

```
install.packages("psych")
```

```
library(psych)
```

```
Factores <- read_excel("Libny/UCM_MCAF/TFM/Factores.xlsx",sheet = "Hoja1 (2)")
```

```
summary(Factores)
```

```
Rcor <- cor(Factores, use = "pairwise.complete.obs" )
```

```
Rcor
```

```
det(Rcor)
```

```
bartlett.test(Factores)
```

```
KMO(Factores)
```

ANEXO 6. MATRIZ DE CORRELACIONES - ANÁLISIS FACTORIAL

		LIQ1	LIQ2	LIQ3	CCRED1	CCRED2	CCRED3	SOLV1	SOLV2	RENT1	RENT2	Eficiencia	LogActivo	LogPatrimonio	LogIngreso	Balanza	IPC	PIB	Desempleo	LogPerCapita
Correlación	LIQ1	1.000																		
	LIQ2	-0.560	1.000																	
	LIQ3	-0.434	0.618	1.000																
	CCRED1	0.027	-0.043	-0.060	1.000															
	CCRED2	0.286	-0.170	-0.160	0.034	1.000														
	CCRED3	0.090	0.133	-0.020	0.021	0.830	1.000													
	SOLV1	-0.041	-0.260	0.073	0.020	-0.136	-0.127	1.000												
	SOLV2	0.127	-0.270	-0.070	-0.006	-0.054	-0.063	0.826	1.000											
	RENT1	0.124	-0.090	0.008	-0.024	0.062	0.068	0.428	0.195	1.000										
	RENT2	0.162	-0.130	-0.030	-0.034	0.173	0.167	0.408	0.214	0.980	1.000									
	Eficiencia	-0.280	0.241	0.164	0.102	-0.127	-0.195	-0.162	-0.160	-0.272	-0.312	1.000								
	LogActivo	-0.262	0.398	0.161	0.005	-0.284	-0.180	-0.297	-0.253	-0.319	-0.374	0.076	1.000							
	LogPatrimonio	-0.440	0.319	0.220	0.029	-0.581	-0.419	0.155	0.000	-0.154	-0.262	0.126	0.798	1.000						
	LogIngreso	-0.350	0.469	0.207	0.000	-0.276	-0.156	-0.198	-0.243	-0.057	-0.113	0.100	0.941	0.793	1.000					
	Balanza	-0.040	0.003	0.036	0.104	0.052	0.088	0.065	0.105	0.005	-0.018	0.003	-0.018	-0.009	-0.017	1.000				
	IPC	-0.060	0.035	-0.010	-0.017	0.103	0.121	0.040	0.041	0.021	0.040	0.039	0.014	-0.002	0.054	-0.302	1.000			
	PIB	0.077	-0.020	-0.030	-0.078	-0.128	-0.173	-0.089	-0.126	-0.019	-0.014	-0.035	0.005	0.008	-0.026	-0.662	-0.510	1.000		
	Desempleo	-0.083	0.036	0.005	0.023	0.104	0.134	0.056	0.069	0.030	0.045	0.022	0.005	-0.019	0.050	-0.107	0.878	-0.570	1.000	
	LogPerCapita	-0.091	0.035	0.014	0.047	0.122	0.161	0.074	0.097	0.030	0.039	0.027	0.002	-0.018	0.047	0.157	0.830	-0.780	0.961	1.000

Fuente: Elaboración propia

ANEXO 7. RATIOS FINANCIEROS CALCULADOS PARA CADA BANCO PARA EL AÑO 2018

Banco	Liquidez			Calidad del Crédito			Solvencia		Rentabilidad			Eficiencia	Tamaño		
	Activos líquidos / Activo	Crédito / Activo	Crédito / Depósito	Provisiones/ Créditos Vencidos	Provisiones/ Créditos	Provisiones/ Activos	Patrimonio/ Activo	Patrimonio/ Pasivo	ROA	Ingresos netos / Activo medio	ResulExplot / Activo medio	EgresOper / IngrOperat	LogActivos	LogPatrimonio	LogIngreso por intereses
BNP	0.22	0.46	0.52	1.78	0.01	0.01	0.09	0.10	0.019	0.031	0.047	0.23	6.96	5.91	5.58
CA	0.14	0.73	0.84	0.55	0.02	0.01	0.09	0.10	0.012	0.023	0.044	0.76	6.59	5.56	5.27
BG	0.08	0.64	0.91	0.99	0.01	0.01	0.07	0.08	0.020	0.029	0.050	0.51	7.23	6.10	5.93
TWB	0.12	0.76	0.97	2.08	0.01	0.01	0.10	0.11	0.013	0.023	0.040	0.82	6.00	5.00	4.71
BVV	0.10	0.77	1.09	0.35	0.01	0.01	0.09	0.09	-0.005	0.020	0.045	1.31	6.25	5.19	5.00
Mbank	0.07	0.66	1.09	0.92	0.01	0.01	0.11	0.12	0.014	0.021	0.031	0.81	6.68	5.71	5.38
Mebank	0.09	0.65	0.82	0.93	0.01	0.01	0.10	0.11	0.008	0.021	0.036	1.35	6.14	5.15	4.90
Aliado	0.14	0.64	0.98	2.15	0.01	0.00	0.10	0.11	0.011	0.017	0.025	1.83	6.43	5.43	5.14
CrediC	0.13	0.66	0.96	0.50	0.01	0.01	0.14	0.16	0.015	0.021	0.047	0.58	6.25	5.40	4.94
Global	0.07	0.71	1.26	0.70	0.02	0.01	0.11	0.13	0.013	0.017	0.032	0.80	6.84	5.90	5.55
MMG	0.19	0.21	0.26	22.57	0.00	0.00	0.06	0.06	0.013	0.011	0.039	0.27	5.59	4.37	3.98
Delta	0.07	0.62	0.95	1.62	0.02	0.01	0.12	0.13	0.010	0.055	0.130	0.54	5.48	4.54	4.48
Capital	0.12	0.69	0.89	1.29	0.01	0.01	0.07	0.08	0.009	0.015	0.035	0.76	6.15	5.00	4.85
BPMá	0.08	0.65	0.92	0.47	0.00	0.00	0.11	0.13	0.013	0.022	0.034	1.11	6.11	5.17	4.84
Prival	0.18	0.59	0.71	0.64	0.00	0.00	0.11	0.12	0.005	0.020	0.043	0.80	5.83	4.87	4.47
Hipo	0.05	0.77	2.41	0.06	0.00	0.00	0.10	0.11	0.004	0.013	0.035	1.42	5.81	4.79	4.50
Unibank	0.06	0.71	0.88	0.64	0.01	0.01	0.11	0.12	0.005	0.020	0.034	1.21	5.73	4.77	4.48
Canal	0.14	0.61	0.71	0.41	0.03	0.02	0.10	0.11	0.002	0.021	0.054	0.66	5.63	4.63	4.32
Citi	0.26	0.19	0.21	0.09	0.00	0.00	0.05	0.06	0.027	0.022	0.045	0.04	6.09	4.82	4.46
Davivien	0.20	0.57	0.69	187.94	0.02	0.01	0.13	0.15	0.007	0.022	0.036	0.80	6.11	5.22	4.74
Mega	0.05	0.90	1.26	4.81	0.09	0.08	0.27	0.37	0.021	0.034	0.049	0.39	5.32	4.75	4.03
NovaS	0.12	0.83	0.86	1.10	0.03	0.02	0.02	0.02	-0.001	0.032	0.070	0.48	6.57	4.79	5.25
BICSA	0.11	0.80	1.80	1.52	0.01	0.01	0.12	0.13	0.007	0.020	0.035	1.26	6.28	5.35	5.01
Bladex	0.23	0.74	1.91	1.54	0.02	0.01	0.13	0.15	0.002	0.016	0.030	0.61	6.88	6.00	5.41
Mercan	0.11	0.68	0.75	6.60	0.02	0.01	0.08	0.09	0.012	0.031	0.054	0.24	5.74	4.66	4.30
Pacífico	0.22	0.16	0.21	0.41	0.01	0.00	0.20	0.25	0.000	0.018	0.041	1.32	4.94	4.24	3.59
Keb.Ha	0.13	0.86	0.94	0.13	0.00	0.00	0.07	0.07	0.017	0.022	0.037	0.44	5.44	4.27	4.01
Banesco	0.17	0.66	0.80	0.80	0.02	0.01	0.10	0.11	0.007	0.027	0.059	0.40	6.62	5.61	5.28
BCT	0.09	0.79	0.92	0.48	0.06	0.04	0.10	0.11	0.014	0.038	0.081	0.67	5.95	4.94	4.82
BChina	0.17	0.83	0.91	2.83	0.01	0.01	0.08	0.09	0.015	0.019	0.024	0.42	6.38	5.31	4.89
Bac	0.13	0.46	0.83	1.99	0.03	0.01	0.32	0.47	0.049	0.020	0.043	0.28	6.93	6.43	5.53

Georges	0.06	0.73	0.85	1.75	0.02	0.02	0.06	0.06	0.011	0.031	0.063	0.78	6.22	4.99	5.07
ScotiaB	0.75	0.00	0.00	0.00	0.00	0.00	0.99	90.75	-0.018	0.067	0.067	0.07	4.89	4.89	4.38
Azteca	0.15	0.54	1.21	2.07	0.05	0.03	0.43	0.76	0.043	0.512	0.920	0.04	4.69	4.32	4.43
Pichinch	0.11	0.46	0.62	0.67	0.01	0.01	0.09	0.10	0.012	0.024	0.032	0.64	5.92	4.89	4.57
FPB	0.62	0.31	0.42	0.26	0.29	0.09	-0.18	-0.15	-0.035	0.013	0.070	0.02	4.87	0.00	3.08
Banisi	0.05	0.79	0.97	0.69	0.01	0.01	0.10	0.11	0.012	0.031	0.066	0.63	5.65	4.65	4.39
G&T	0.21	0.10	0.12	0.86	0.04	0.00	0.13	0.15	-0.030	0.023	0.053	0.94	4.89	4.01	3.58
BBP	0.15	0.68	0.77	1.63	0.01	0.01	0.11	0.12	0.008	0.026	0.044	0.67	5.43	4.47	4.11
Lafise	0.12	0.52	0.65	4.50	0.01	0.01	0.07	0.08	0.007	0.020	0.040	0.69	5.68	4.53	4.29
AllBank	0.19	0.39	0.47	0.44	0.05	0.02	0.12	0.14	0.014	0.022	0.042	0.55	5.36	4.44	4.04
BnColom	0.30	0.69	1.39	0.00	0.02	0.02	0.08	0.09	0.001	0.019	0.037	1.15	5.86	4.79	4.45
Ficohsa	0.11	0.75	0.83	0.99	0.02	0.01	0.06	0.07	0.006	0.034	0.075	0.62	5.70	4.50	4.52
Bogotá	0.07	0.64	2.49	0.00	0.01	0.01	0.31	0.45	0.019	0.029	0.046	0.34	4.66	4.15	3.34
Banist	0.09	0.73	1.05	1.23	0.03	0.02	0.11	0.12	0.009	0.029	0.063	0.56	6.98	6.01	5.71
BiBank	0.32	0.43	0.49	0.62	0.01	0.00	0.12	0.14	0.022	0.056	0.122	0.63	5.35	4.43	4.39
Atlas	0.42	0.00	0.00	0.00	0.00	0.00	0.81	4.13	-0.080	0.018	0.094	0.11	4.43	4.34	2.71

Fuente: Elaboración propia

ANEXO 8. PROMEDIO DE RATIOS FINANCIEROS POR AÑO

Año	Liquidez			Calidad del Crédito			Solvencia		Rentabilidad			Eficiencia	Tamaño		
	Activos liquidos / Activo	Crédito / Activo	Crédito / Depósito	Provisiones/ Créditos Vencidos	Provisiones/ Créditos	Provisiones/ Activos	Patrimonio/ Activo	Patrimonio/ Pasivo	ROA	Ingresos netos / Activo medio	Resultados Explorados / Activo medio	Egresos Operativos / Ingresos Operativos	Log Activos	Log Patrimonio	Log Ingresos por intereses
2015	17.90%	58.85%	87.75%	331.01%	1.13%	0.63%	10.80%	12.73%	0.65%	3.20%	6.07%	62.71%	5.93	4.90	4.55
2016	17.74%	59.99%	86.90%	115.70%	1.81%	0.93%	11.16%	13.20%	0.51%	3.20%	6.53%	68.44%	5.96	4.95	4.61
2017	16.34%	60.59%	86.22%	196.41%	1.94%	1.06%	11.23%	13.43%	0.29%	3.61%	7.57%	65.07%	5.95	4.88	4.64
2018	16.50%	59.11%	88.52%	562.98%	2.35%	1.31%	14.58%	22.61%	0.76%	3.56%	6.89%	67.21%	5.91	4.88	4.61

Fuente: Elaboración propia